

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E SANEAMENTO
AMBIENTAL**

**MONITORAMENTO E MODELAGEM DA
PRODUÇÃO DE SEDIMENTOS EM UMA BACIA
HIDROGRÁFICA NO NOROESTE DO RIO GRANDE
DO SUL**

TESE DE DOUTORADO

Vanessa Sari

Porto Alegre, RS, Brasil

2017

VANESSA SARI

**MONITORAMENTO E MODELAGEM DA
PRODUÇÃO DE SEDIMENTOS EM UMA BACIA
HIDROGRÁFICA NO NOROESTE DO RIO GRANDE
DO SUL**

Tese submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul como requisito parcial para obtenção do título de **Doutor em Recursos Hídricos e Saneamento Ambiental**.

Orientadora: Profa Dra Nilza Maria dos Reis Castro

Porto Alegre, RS, Brasil

2017

CIP - Catalogação na Publicação

Sari, Vanessa

Monitoramento e modelagem da produção de sedimentos em uma bacia hidrográfica no Noroeste do Rio Grande do Sul / Vanessa Sari. -- 2017.

312 f.

Orientadora: Nilza Maria dos Reis Castro.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Porto Alegre, BR-RS, 2017.

1. processos erosivos. 2. produção de sedimentos.
3. redes neurais artificiais. 4. modelo SWAT. I.
Castro, Nilza Maria dos Reis, orient. II. Título.

VANESSA SARI

**MONITORAMENTO E MODELAGEM DA PRODUÇÃO DE
SEDIMENTOS EM UMA BACIA HIDROGRÁFICA NO NOROESTE DO
RIO GRANDE DO SUL**

Tese submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul como requisito parcial para obtenção do título de **Doutor em Recursos Hídricos e Saneamento Ambiental**.

BANCA EXAMINADORA:

Nilza Maria dos Reis Castro, Dra (Orientadora, IPH/UFRGS)

Cláudia Weber Corseuil, Dra (UFSC)

Olavo Correa Pedrollo, Dr (IPH/UFRGS)

Tirzah Moreira Siqueira, Dra (UFPel)

Porto Alegre, 28 de dezembro de 2017

Aos meus pais, Dorvalino e Anair Sari, pelo amor, apoio e compreensão e por me ensinarem a importância da família e a sempre lutar pelos meus sonhos...

Ao meu irmão, Márcio Sari, pelo carinho e apoio...

A minha irmã e companheira de todas as horas, Vanúzia Sari, pelo amor e apoio incondicional, por compartilhar minhas angústias e dúvidas e me sustentar no trilhar dessa caminhada...

DEDICO.

AGRADECIMENTOS

Tento agora recuperar as imagens e palavras de minhas vivências que construíram esta parte de minha história de vida e que me vêm à mente numa conjunção de momentos: rostos, acontecimentos, sentimentos, palavras – agradáveis e menos agradáveis...

A Deus... não é possível expressar, em palavras, meus agradecimentos! Sem Ele esse trabalho não seria possível! Gratidão sempre!

À Universidade Federal do Rio Grande do Sul (UFRGS) e ao Instituto de Pesquisas Hidráulicas (IPH), em especial aos professores do Curso de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, que possibilitaram a realização desse curso de doutorado.

Ao INMET, pelo fornecimento dos dados meteorológicos da estação de Cruz Alta-RS, essenciais à realização dos estudos de modelagem efetuados.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de doutorado fornecida, sem a qual não seria possível a dedicação exclusiva para o desenvolvimento desse trabalho. Estendo meus agradecimentos também à FINEP, pelo financiamento dessa pesquisa através dos projetos "Rede de Pesquisa em Monitoramento e Modelagem de Processos Hidrossedimentológicos em Bacias Representativas Rurais e Urbanas do Bioma Mata Atlântica" e; "Produtos e processos para avaliação do aporte de sedimentos visando a disponibilidade hídrica em reservatórios de geração de energia".

Ao Laboratório de Sedimentos do IPH pela estrutura disponibilizada durante a realização das análises laboratoriais, fundamentais ao desenvolvimento desse estudo.

À minha orientadora, profa Dra Nilza Maria dos Reis Castro, pelo carinho, apoio, amizade e motivação, pelo exemplo e dedicação, pelos ensinamentos, pelos momentos de reflexão e discussão e; por partilhar sua experiência, nas várias etapas do desenvolvimento desse trabalho: meu especial agradecimento e minha gratidão! Sem dúvida, seu incentivo, sua ajuda e sua compreensão foram fundamentais para a finalização dessa pesquisa!

Ao prof Dr Olavo Correa Pedrollo, pelos conhecimentos partilhados na área de estatística, software MatLab® e redes neurais artificiais, por seu auxílio e suas contribuições no desenvolvimento dos modelos, pelos ensinamentos, esclarecimentos e ajuda durante todo o processo de modelagem com redes neurais artificiais: meu sincero agradecimento!

Agradecimentos aos membros das bancas de qualificação e de defesa da tese, profa Dra Eloiza Maria Cauduro Dias de Paiva (*In Memoriam*), Profa Dra Cláudia Weber Corseuil, Prof Dr João Batista Dias de Paiva, Profa Dra Nádia Bonumá, Prof Dr Olavo Correa Pedrollo e

Professora Dra Tirzah Moreira Siqueira, pelas contribuições, críticas e sugestões ofertadas para a melhoria desse trabalho. Agradecimentos especiais à profa Nádia e ao prof João Batista pelos ensinamentos oferecidos durante os cursos sobre modelagem hidrossedimentológica com o modelo SWAT. Estendo meus agradecimentos também à colega Tássia Mattos Brighenti, pelos ensinamentos sobre SWAT-CUP transmitidos durante o curso de modelagem hidrossedimentológica com o modelo SWAT.

Aos meus pais, Dorvalino Luiz Sari e Anair Garlet Sari: sempre recordarei da expressão e das palavras de apoio, carinho, incentivo e acima de tudo do amor incondicional que me dedicaram, constantemente, durante essa caminhada, entendendo meus momentos de ausência, medo e ansiedade: obrigada não seria suficiente! Minha eterna gratidão por compartilharem comigo essa jornada!

Aos meus irmãos Márcio e Vanúzia, que estiveram presentes, me auxiliando e incentivando, minha profunda gratidão! Em especial a minha irmã (Núzia), base de minha segurança, alicerce de meu crescimento, companheira de todas as horas, quem sempre me estimulou a continuar, me deu carinho, atenção e apoio, entendeu minhas lágrimas e ofereceu as palavras necessárias para ir adiante. Um ser iluminado que, com certeza, me acompanha por vidas e vidas! Um verdadeiro “anjo” guiando minha caminhada! Não teria como expressar em palavras tudo aquilo que você representa para mim! Gratidão eterna!

Aos colegas e amigos com quem compartilhei horas de trabalho, privações de sono e descanso nos momentos das coletas de campo, mas com quem também vivenciei momentos de alegria, descontração e lazer. Amigos com quem dividi situações de decisões necessárias, de resolução dos problemas, as idas a campo, as aflições e os anseios dessa pesquisa. Em especial aos companheiros de jornada Marquis Henrique Campos de Oliveira e Aron Jonatã Funke (técnico do Laboratório de Sedimentos), com quem compartilhei as fatídicas madrugadas de coleta! Agradecimentos especiais também ao meu colega e amigo Felipe Mamédio, ao técnico Pedro Massochin Medeiros e a amiga Rubmara Ketzer de Oliveira! A todos vocês, que comigo também colocaram a “mão na massa”, enfrentaram o frio e a chuva, para me auxiliar nas coletas de campo! Meu verdadeiro agradecimento! Esse trabalho não teria sido concretizado sem a preciosa ajuda que recebi de vocês!

Agradecimento especial ao colega Felipe Mamédio, com quem compartilhei as dúvidas e as buscas pelas soluções dos problemas com a modelagem hidrossedimentológica no SWAT e também, com a calibração automática no SWAT-CUP. Obrigada por todas as contribuições e

conversas até altas horas, buscando sanar todas as dúvidas e os problemas encontrados ao longo desse percurso!

Agradeço também à equipe do laboratório de sedimentos, em especial aos técnicos Bruno da Silva Rocha e (mais uma vez) ao Aron Jonatã Funke), e aos estagiários Lucas Pires, Guiniver, Ana Karolina Rodrigues da Silveira, Silvia Pereira Marengo e Ingrid Vaz, pela ajuda durante a realização das análises de laboratório, essenciais à continuidade dessa pesquisa. Especiais agradecimentos à Ingrid Vaz e ao bolsista Luis Henrique Dieter, por toda a ajuda fornecida na organização dos dados de entrada necessários para a simulação do modelo SWAT!

À equipe da hidrometria e aos motoristas do IPH, pelo auxílio prestado durante os trabalhos de campo: Cesar Dias Gonçalves, Luis Gregório Raupp, Gilnei Ricardo da Silva, Pedro Varny Silva da Silva, Mário Cardoso, Anselmo Einloft, assim como aos motoristas terceirizados: muito obrigada pelo apoio durante essas jornadas de campo!

Não poderia ainda deixar de agradecer a uma pessoa especial, que entrou em minha vida no ano de 2003, uma amiga e colega com quem posso contar! Obrigada Dé (Débora Míssio)!

Agradeço também aos demais colegas, com os quais partilhei momentos de descontração e crescimento, em especial: ao Jones pelas conversas, ao Carlos pelos bate-papos e pelas traduções ao Espanhol (mesmo quando estava longe, oferecendo ajuda por e-mail) e; à Haline Depiné que, mesmo distante e enfrentando os desafios da maternidade, reservou um tempo para me auxiliar com as dúvidas relativas à modelagem e ao preenchimento de falhas pluviométricas.

Meus agradecimentos também ao casal sr. Antoninho Zambra, sra. Fátima e toda sua família, proprietários das áreas onde foram realizados os experimentos. A concretização dessa pesquisa não seria possível sem vocês!

Ao pessoal do hotel de Pejuçara (família Miller) e de Cruz Alta (família Pinheiro), pelo carinho e apoio durante os intervalos dos cansativos trabalhos de campo!

À Prefeitura Municipal de Pejuçara que sempre estava à disposição para ajudar no que fosse necessário.

E a todos aqueles que, direta ou indiretamente, auxiliaram na minha formação acadêmica e no desenvolvimento dessa pesquisa, meu muito obrigada!

“The important thing in science is not so much to obtain new facts as to discover a new ways to think about them.”

(Sir Willian Lawrence Bragg)

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental
Universidade Federal do Rio Grande do Sul
Instituto de Pesquisas Hidráulicas

MONITORAMENTO E MODELAGEM DA PRODUÇÃO DE SEDIMENTOS EM UMA BACIA HIDROGRÁFICA NO NOROESTE DO RIO GRANDE DO SUL

AUTORA: Vanessa Sari

ORIENTADORA: Nilza Maria dos Reis Castro

Data e Local da Defesa: Porto Alegre, 28 de dezembro de 2017

RESUMO: O entendimento da dinâmica hidrossedimentológica em uma bacia hidrográfica pode ser realizado pelo monitoramento das variáveis hidrossedimentológicas e pela modelagem desses processos. Nesse contexto, essa pesquisa analisou a eficiência do modelo *Soil and Water Assessment Tool* (SWAT) na previsão dos processos hidrossedimentológicos na bacia do Taboão (Pejuçara, RS), considerando as saídas (vazão e produção de sedimentos) em um passo de tempo mensal e diário. Para tal, foram utilizados dados de chuva horária dos anos 2008 a 2016, monitorada em quatro pluviógrafos instalados na bacia (PVGs 34, 40, 43 e 51), e dados climáticos da estação meteorológica de Cruz Alta. As informações de vazão, para os anos de 2011 a 2016, foram obtidas por meio da conversão dos dados de nível de água monitorados no exutório da bacia, utilizando uma curva-chave cota x vazão. A concentração de sedimentos suspensos (CSS), para os anos de 2013 a 2015, foi estimada por meio de modelos de redes neurais artificiais (RNAs), empregando como entrada dados de turbidez e de nível de água, monitorados no exutório da bacia. O preenchimento das falhas dos registros de precipitação horária foi executado por meio de modelos de Combinações de RNAs (CRNAs) associados à média simples (MS) ou à média ponderada pelo inverso da distância (MP), utilizando como entrada dados pluviométricos dos postos vizinhos. As falhas nos dados de nível de água foram preenchidas por modelos de RNAs, que usaram como entrada níveis de água monitorados em sub-bacias embutidas ou adjacente à bacia do Taboão (bacias do Donato, Turcato, Alemão e Andorinhas), e dados de precipitação média dos quatro pluviógrafos utilizados nessa pesquisa. Foram determinadas as defasagens temporais entre os níveis de água das diferentes bacias, e testados o uso da precipitação média com aplicação de filtro temporal linear e/ou exponencial. Os registros falhos nos dados de turbidez foram preenchidos por modelos de RNAs, que empregaram como entrada informações de nível de água monitoradas, de 10 em 10 minutos, no exutório da bacia. A calibração do modelo SWAT para a previsão dos processos hidrológicos foi realizada usando dados de vazão, diários e mensais, para os anos de 2013, 2014 e 2016 e; a etapa de verificação foi executada para os anos de 2011 e 2015. Considerou-se o Método de Green & Ampt para determinação da infiltração de água no solo e 2 anos (2008-2009) para período de aquecimento do modelo SWAT. A calibração do modelo para a produção de sedimentos foi realizada para os anos de 2013 e 2015 e o processo de verificação foi efetuado para o ano de 2014. A calibração e a análise de sensibilidade dos parâmetros foram realizadas com auxílio do SWAT-CUP, utilizando o algoritmo SUFI-2. O coeficiente de Nash-Sutcliffe (NS) das RNAs para preenchimento das falhas de precipitação variou entre 0,35, classificado como “Insatisfatório”, e 0,86, avaliado como “Muito Bom”, considerando critérios propostos

por Moriasi et al. (2007). Das 13 RNAs desenvolvidas para preenchimento das falhas nos níveis de água, apenas uma delas foi classificada como de desempenho “Satisfatório” durante o treinamento e; as demais enquadraram-se como de desempenho “Muito Bom”. Na etapa de verificação, sete RNAs foram consideradas com desempenho “Muito Bom” e cinco com “Bom” desempenho. No preenchimento das falhas de turbidez, das cinco RNAs desenvolvidas, quatro mostraram “Bom” desempenho durante o treinamento, e uma rede teve desempenho “Muito Bom”; enquanto que, no processo de verificação, duas RNAs tiveram desempenho “Muito Bom”, uma delas foi classificada com desempenho “Bom” e; duas RNAs foram consideradas com desempenho “Satisfatório”. As estatísticas de desempenho dos modelos de RNAs desenvolvidos para o preenchimento das falhas de nível de água, de turbidez e de precipitação também demonstraram que tais redes representam uma alternativa interessante para a obtenção de séries contínuas desses dados, possibilitando o uso posterior dos registros para a modelagem hidrossedimentológica. A calibração do modelo SWAT para estimativa da vazão mensal mostrou desempenho “Muito Bom” (NS=0,78), e para a determinação da vazão diária foi considerado “Bom” (NS=0,72). Na etapa de verificação, o modelo manteve o “Bom” desempenho (NS=0,68) para estimativa da vazão diária, decaindo para desempenho “Satisfatório” (NS=0,64) para a simulação em escala mensal. Para a estimativa da produção de sedimentos mensal, o desempenho do modelo foi considerado “Bom” tanto na calibração (NS=0,66) quanto na verificação (NS=0,70). Na escala diária o desempenho foi “Satisfatório” para a calibração (NS=0,64) e “Insatisfatório” para a verificação (NS=0,38). Tais resultados indicam que o modelo SWAT é uma ferramenta promissora para aplicações na previsão hidrossedimentológica na bacia do Taboão, especialmente em termos de simulações dos processos hidrológicos. No entanto, existem limitações para aplicações na estimativa da produção de sedimentos, sobretudo quando considerados os processos em escala diária. Essas limitações são consequência da presença de processos erosivos na bacia (voçorocas), que não são simulados pelas rotinas presentes no modelo SWAT, bem como pelo escoamento dominante ser do tipo subsuperficial, com ocorrência de *pipping*; indicando-se, portanto, adequações nas rotinas do modelo para melhor representatividade desses processos.

Palavras-chave: processos erosivos, produção de sedimentos, modelo SWAT, redes neurais artificiais.

ABSTRACT

Doctor Science Thesis
Graduate Program in Water Resources and Environmental Sanitation
Federal University of Rio Grande do Sul
Institute of Hydraulic Research

MONITORING AND MODELLING OF SEDIMENT YIELD IN A WATERSHED IN THE NORTHWEST OF RIO GRANDE DO SUL

AUTHOR: Vanessa Sari

ADVISER: Nilza Maria dos Reis Castro

Defense Place and Date: Porto Alegre, December 28, 2017.

ABSTRACT: The understanding of hydrosedimentological dynamics in a watershed can be obtained by monitoring the hydrosedimentological variables and by modeling these processes. In this context, this research analyzed the efficiency of the Soil and Water Assessment Tool (SWAT) in predicting the hydrosedimentological processes in the Taboão basin (Pejuçara, RS), considering the outputs (flow and sediment production) in a monthly and daily time step. For that, hourly rainfall data from 2008 to 2016 were monitored at four pluviographs installed in the basin (PVGs 34, 40, 43 and 51), and climate data were obtained from the Cruz Alta meteorological station. The flow information for the years 2011 to 2016 was obtained by converting the monitored water level data into flow by using a rating curve. The suspended sediment concentration (SSC), from 2013 to 2015, was estimated using artificial neural network (ANN) models, using as input turbidity and water level data, monitored in the basin. The filling of the hourly rainfall records was performed by models of Combinations of RNAs (CRNAs) associated with the simple mean (MS) or weighted mean to the inverse distance (MP), using as input rainfall data from the neighboring stations. Failures in the water-level data were filled by RNA models, which used as input water levels monitored in sub-basins adjacent or embedded to the Taboão basin (Donato, Turcato, Alemão and Andorinha basins), and mean precipitation data of the four pluviographs used in this research. The temporal lags between the water levels of the different basins were determined and the use of the average precipitation with linear and exponential temporal filters was tested. The turbidity data records were filled by RNA models, using water level information monitored at every 10 minutes. The SWAT model calibration for predicting the hydrological processes was performed using daily and monthly flow data for the years 2013, 2014 and 2016 and the verification step was performed for the years 2011 and 2015; considering Green & Ampt Method for infiltration estimation and 2 years of warm-up period (2008-2009). The calibration of the model for sediment yield was performed for the years 2013 and 2015 and the verification process was carried out for the year 2014. The calibration and sensitivity analysis of the parameters were performed with the assistance of SWAT-CUP, using the SUFI-2 algorithm. The Nash-Sutcliffe Coefficient (NS) of the RNAs used to fill precipitation faults varied between 0.35, classified as "Unsatisfactory", and 0.86, evaluated as "Very Good", considering criteria proposed by Moriasi et al. (2007). Of the 13 RNAs developed to fill water level failures, only one of them was classified as a "Satisfactory" performance during training and; the others have been classified as "Very Good" performance. In the verification step, seven RNAs were considered to have "Very Good" performance and five had "Good" performance. In the fulfillment of the turbidity faults, of the five RNAs developed, four showed "Good" performance during the training, and one network had "Very Good"

performance; while in the verification process two ANNs performed "Very Good", one of them was classified as "Good" and; two ANNs were considered to have "Satisfactory" performance. The performance statistics of the ANN models developed to fill the water level, turbidity and precipitation failures also demonstrated that such networks represent an interesting alternative to obtain continuous series of these data, allowing the later use of the records for hydrosedimentological modeling. In the verification processes, the model maintained a "Good" performance (NS=0.68) to estimate the daily flow, decreasing to "Satisfactory" performance (NS=0.64) for the monthly scale simulation. For the estimation of sediment yield the model performance was considered "Good" for monthly calibration period (NS=0.66) and also for the verification (NS=0.70). In daily scale the performance was "Satisfactory" for calibration (NS=0.64) and "Unsatisfactory" in the verification (NS=0.38). These results indicate that the SWAT model is a promising tool for applications in the hydrosedimentological forecasting in the Taboão basin, especially in terms of hydrological processes simulations. However, there are limitations to applications in the estimation of sediment production, especially when considering daily scale processes. These limitations are due to the presence of erosive processes in the basin (gully erosion), which are not simulated by the routines present in the SWAT model, as well as by the existence of the lateral flow with occurrence of *pipping*; indicating, therefore, the need for adjustments in the routines of the model to better represent these processes.

Key words: erosive processes, sediment yield, SWAT model, artificial neural networks.

LISTA DE FIGURAS

Figura 1 - Exemplo de amostragem pelo método de igual incremento de largura (IIL)	42
Figura 2 - Variação da turbidez em função da concentração de sedimentos suspensos (CSS) para um sensor DTS-12. Calibração realizada em laboratório utilizando amostras de sedimento suspenso coletadas <i>in situ</i>	46
Figura 3 - Relação entre a concentração de sedimentos suspensos (CSS) e a turbidez (T), considerando diferentes faixas granulométricas	50
Figura 4 - Relação Turbidez/CSS para diferentes diâmetros da partícula de sedimento	51
Figura 5 - Relação turbidez (T) e concentração de sedimentos suspensos (CSS) para três sensores DTS-12, com características geométricas semelhantes	53
Figura 6 - Resposta do sensor OBS em função da CSS, para diferentes cores de sedimentos suspensos	56
Figura 7 - Variação da resposta do sensor DTS-12 em função das condições de agitação da amostra: (a) turbidez para concentrações de sedimento suspenso (CSS) entre 0,01 e 0,1 g/L e; (b) turbidez para CSS superiores a 0,1 g/L	63
Figura 8 - Variação da resposta de um sensor óptico em função de características do sedimento transportado, da presença de bolhas de ar e outros componentes na coluna de água e da ocorrência de processos de turbulência e floculação	64
Figura 9 - Representação de uma rede neural artificial <i>feedforward</i> com três camadas	77
Figura 10 - Localização da bacia hidrográfica do Taboão, no contexto brasileiro e regional	111
Figura 11 - Mapa de uso do solo da bacia do Taboão	114
Figura 12 - Mapa de tipo de solo da bacia do Taboão	116
Figura 13 - Mapa da variação da altimetria na bacia do Taboão	119
Figura 14 - Curva-chave para determinação da vazão em função da variação do nível de água, na bacia do Taboão	120
Figura 15 - Sensor de turbidez (DTS-12 SDI Turbidity Sensor) e no detalhe a superfície óptica e a lâmina de limpeza	121
Figura 16 - Sistema de guincho instalado na bacia do Taboão para coleta de amostras água-sedimento e monitoramento da vazão	123
Figura 17 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados de nível de água na bacia do Taboão, utilizando dados de precipitação média e de nível de água em bacias embutidas ou adjacente à bacia do Taboão	125
Figura 18 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados de turbidez na bacia do Taboão, utilizando dados de nível de água monitorados no exutório da bacia	128
Figura 19 - Esquema representativo da RNA desenvolvida para estimativa da CSS na bacia do Taboão, utilizando dados de turbidez e de nível de água monitorados no exutório da bacia.	132
Figura 20 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados horários de precipitação na bacia do Taboão, utilizando dados de precipitação de outros pluviógrafos vizinhos ao PVG falho	147
Figura 21 - Variação da CSS e turbidez (a), variação do nível de água (b) e relação nível de água-turbidez (c), para os eventos analisados entre junho de 2013 e outubro de 2015	157
Figura 22 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os	

processos de treinamento e de verificação do modelo Don_Chu_And_valcruz_2016maijul, respectivamente, para o ano de 2016 e as variáveis de entrada nível de água (Donato e Andorinhas) e chuva média com aplicação de filtro exponencial.	172
Figura 23 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chu_And_Ale_valcruz_2015, respectivamente, para o ano de 2015 e as variáveis de entrada nível de água (Donato, Alemão e Andorinhas) e chuva média com aplicação de filtro exponencial.	173
Figura 24 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chu_valcruz_2015, respectivamente, para o ano de 2015 e as variáveis de entrada nível de água (Donato) e chuva média com aplicação de filtro exponencial.	174
Figura 25 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chu_valcruz_2010janjul, respectivamente, para o ano de 2010 e as variáveis de entrada nível de água (Donato) e chuva média com aplicação de filtro exponencial.	175
Figura 26 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Chu_valcruz_2010janjul, respectivamente, para o ano de 2010 e a variável de entrada chuva média com aplicação de filtro exponencial.	176
Figura 27 - Turbidez observada e simulada em relação à reta de ajuste ideal (a,e), erro verificado entre os valores calculados e observados de turbidez (b,f), e comportamento dos valores de turbidez calculados e observados; considerando os processos de treinamento (c,g) e de verificação (d,h) das partes 1 e 2 do total de 5 partes de divisão da amostra de dados disponível	182
Figura 28 - - Turbidez observada e simulada em relação à reta de ajuste ideal (a,e), erro verificado entre os valores calculados e observados de turbidez (b,f), e comportamento dos valores de turbidez calculados e observados; considerando os processos de treinamento (c,g) e de verificação (d,h) das partes 3 e 4 do total de 5 partes de divisão da amostra de dados disponível	183
Figura 29 - Turbidez observada e simulada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de turbidez (b), e comportamento dos valores de turbidez calculados e observados (c, d); considerando os processos de treinamento e de verificação da parte 5 do total de 5 partes de divisão da amostra de dados disponível.....	184
Figura 30 - Relações de ajuste entre CSS e turbidez (a), CSS observada e calculada em relação ao ajuste ideal (b), erro verificado entre os valores calculados e observados da CSS (c), e comportamento dos valores calculados e observados para a série de treinamento (d) e de na verificação (e), respectivamente; considerando o melhor modelo de ajuste baseado na variável de entrada turbidez.....	190
Figura 31 - Relações de ajuste entre CSS e nível de água (a), CSS observada e calculada em relação ao ajuste ideal (b), erro verificado entre os valores calculados e observados da CSS (c), e comportamento dos valores calculados e observados para a série de treinamento (d) e de	

verificação (e), respectivamente; considerando o melhor modelo de ajuste baseado na variável de entrada nível de água	191
Figura 32 - CSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados para a série de treinamento (c) e de verificação (d), respectivamente; considerando o melhor modelo de ajuste baseado nas variáveis de entrada turbidez e nível de água	192
Figura 33 - CSS observada e calculada em relação à função de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados, considerando os processos de no treinamento (c) e na verificação (d) do Modelo_0 para as entradas nível de água e turbidez	195
Figura 34 - Divisão dos dados disponíveis para a aplicação do treinamento com validação por reamostragem.....	196
Figura 35 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do Modelo_1, respectivamente, para as variáveis de entrada nível de água e turbidez	197
Figura 36 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do Modelo_2, respectivamente, para as variáveis de entrada nível de água e turbidez.....	199
Figura 37 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo NívCSS_1, respectivamente, para a variável de entrada nível de água.....	201
Figura 38 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo NívCSS_2, respectivamente, para a variável de entrada nível de água.....	202
Figura 39 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo TurbCSS_1, respectivamente, para a variável de entrada turbidez	204
Figura 40 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo TurbCSS_2, respectivamente, para a variável de entrada turbidez	205
Figura 41 - Resultados da análise de sensibilidade para a calibração dos parâmetros para a simulação da vazão diária na bacia do Taboão, utilizando o Método de Green & Ampt	213
Figura 42 - Resultados dos processos hidrológicos simulados no modelo SWAT: variação da vazão média simulada e observada em relação a precipitação ocorrida (a); vazão média simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados de vazão média (c), considerando passo de tempo mensal, para a calibração e a verificação.	219
Figura 43 - Resultados dos processos hidrológicos simulados no modelo SWAT: variação da vazão média simulada e observada em relação a precipitação ocorrida (a); vazão média simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados de vazão média (c), considerando passo de tempo diário, para a calibração e a verificação.	221

Figura 44 - Ocorrência de El Niño e La Niña de 1877 a 2010	225
Figura 45 - Resultados da calibração e da verificação da produção de sedimentos simulados no modelo SWAT: variação da produção de sedimentos simulada e observada em relação a precipitação ocorrida (a); produção de sedimentos simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados da produção de sedimentos (c), considerando passo de tempo mensal.	236
Figura 46 - Resultados da calibração e da verificação da produção de sedimentos simulados no modelo SWAT: variação da produção de sedimentos simulada e observada em relação a precipitação ocorrida (a); produção de sedimentos simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados da produção de sedimentos (c), considerando passo de tempo diário.	237
Figura 47 - Distribuição da produção de água e de sedimentos simuladas pelo modelo SWAT para a bacia do Taboão, considerando o ano de 2015	246
Figura 48 - Risco de erosão por voçorocas na bacia do Taboão e voçorocas existentes, considerando o levantamento realizado em 2004.....	247

LISTA DE TABELAS

Tabela 1 - Descrição de estudos internacionais que utilizaram sensores ópticos como medida indireta da CSS	47
Tabela 2 - Turbidez em função da concentração de sedimentos suspensos, para as classes granulométricas areia grossa, areia média, areia fina, silte e mistura silte+argila.	51
Tabela 3 - Descrição de estudos realizados no Brasil utilizando sensores ópticos como medida indireta da CSS	66
Tabela 4 - Influência da posição do parâmetro na Análise de Sensibilidade no processo de Calibração.....	87
Tabela 5 - Parâmetros detectados como de maior sensibilidade, considerando estudos que utilizaram o modelo SWAT em diferentes regiões do Brasil para estimativa dos processos hidrológicos	90
Tabela 6 - Parâmetros detectados como de maior sensibilidade, considerando estudos que utilizaram o modelo SWAT em diferentes regiões do Brasil para estimativa dos processos sedimentológicos	91
Tabela 7 - Efeitos de alguns parâmetros sobre (1) redução do volume de escoamento total, (2) aumento do escoamento de base e recessão do hidrograma, e (3) retardo do escoamento	94
Tabela 8 - Listagem dos parâmetros que podem ser alterados para ajustes da produção de sedimentos	95
Tabela 9 - Classificação do desempenho de um modelo para os principais índices estatísticos utilizados.....	98
Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT.....	102
Tabela 11 - Classes utilizadas no modelo SWAT para a classificação do uso do solo presente na bacia do Taboão	140
Tabela 12 - Classes utilizadas no modelo SWAT para a classificação do tipo de solo presente na bacia do Taboão	141
Tabela 13 - Características físico-hídricas das classes de solo presentes na bacia do Taboão	143
Tabela 14 - Coordenadas de localização e altitude dos pluviógrafo e da estação climatológica	144
Tabela 15 - Coeficientes de desagregação de chuvas de 24 horas de duração	145
Tabela 16 - Dados médios mensais utilizados no modelo SWAT	145
Tabela 17 - Dados climáticos médios mensais utilizados no modelo SWAT	150
Tabela 18 - Parâmetros calibrados e verificados por Depiné (2014) na bacia do Taboão, considerando o período de calibração de 11/01/2002 a 16/09/2004 e de verificação de 01/01/2008 a 31/05/2011	152
Tabela 19 - Resumo dos períodos utilizados no modelo SWAT e no <i>software</i> SWAT-CUP, para cálculos dos parâmetros, realização das simulações e também, para a calibração e a verificação da vazão e da produção de sedimentos na bacia do Taboão.....	154
Tabela 20 - Resultados das amostras coletadas entre junho de 2013 e outubro de 2015	158
Tabela 21 - Características dos postos pluviométricos e dos dados de chuva para o preenchimento dos PVGs 34, 40, 43 e 51, considerando o período de 01/01/2011 a 31/12/2016.....	160
Tabela 22 - Correlações entre os postos pluviométricos com frequência horária	160

Tabela 23 - Correlações entre os postos PVG 34, 40, 43 e 51 e o PVG 13	161
Tabela 24 - Número de ocorrência e frequência (%) de chuva com intensidade maior que 30; 20; 10; 5; 0 mm/h e igual a zero	161
Tabela 25 - Estatísticas para os modelos de preenchimento dos dados horários de chuva para os PVGs 34, 40, 43 e 51, considerando emprego de RNAs, MS e MP	163
Tabela 26 - Desempenho geral dos modelos de CRNAs, MS e MP utilizados para preenchimento dos dados horários dos PVGs 34, 40, 43 e 51.....	164
Tabela 27 - Melhores resultados de desempenho dos modelos de RNAs desenvolvidos para o preenchimento dos dados de nível de água na bacia do Taboão	168
Tabela 28 - Características dos períodos falhos e modelos empregados para o preenchimento dos dados de nível de água na bacia do Taboão, para o período de 2010 a 2016	169
Tabela 29 - Desempenho dos modelos de RNAs na etapa de verificação, para diferentes divisões da série de dados (total de partes), considerando diferentes quantidades de registros (Reg) no processo de treinamento	179
Tabela 30 - Estatísticas de desempenho dos modelos de RNAs para a divisão em 5 partes da amostra total de dados disponível, considerando as etapas de treinamento, validação e verificação	180
Tabela 31 - Estatísticas dos dados de turbidez monitorados (total de dados, dados existentes e dados falhos), considerando o período compreendido entre 2013 e 2015, por ano e para a série total disponível	184
Tabela 32 - Características dos períodos falhos e modelos empregados para o preenchimento das informações de turbidez para o período de 2013 a 2015.....	185
Tabela 33 - Resumo das estatísticas dos modelos ajustados para estimativa da CSS tendo por base informações de nível de água e turbidez	189
Tabela 34 - Resumo das estatísticas diárias das variáveis precipitação, temperatura do ar máxima e mínima, radiação solar, umidade relativa do ar, velocidade do vento, nível de água, vazão, turbidez e CSS para bacia do Taboão; considerando os anos utilizados para a calibração e a verificação do modelo SWAT.....	207
Tabela 35 - Resumo das estatísticas da produção de sedimentos diária e mensal na bacia do Taboão	208
Tabela 36 - Produção de sedimentos na bacia do Taboão, total pluviométrico anual e erosividade da chuva para o PVG 40, considerando os anos de 2013 a 2015.....	208
Tabela 37 - Resultados da análise de sensibilidade para calibração dos parâmetros para a simulação da vazão mensal na bacia do Taboão, utilizando o Método de Green & Ampt	214
Tabela 38 - Rank de sensibilidade dos parâmetros em relação à simulação da vazão diária e mensal na bacia do Taboão, considerando a estatística <i>p-Value</i> e; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006).....	215
Tabela 39 - Intervalo de variação, valores iniciais e valores calibrados dos parâmetros incluídos no processo de calibração do modelo SWAT.....	217
Tabela 40 - Estatísticas de desempenho do modelo SWAT para os processos hidrológicos na bacia do Taboão, no período de calibração e de verificação; considerando um passo de tempo mensal e diário.....	217
Tabela 41 - Componentes hidrológicos médios anuais do balanço hídrico simulado no modelo SWAT.....	228
Tabela 42 - Análise de sensibilidade e rank de sensibilidade dos parâmetros em relação à simulação da produção de sedimentos mensal na bacia do Taboão, considerando a estatística <i>p-</i>	

<i>Value e</i> ; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006).....	231
Tabela 43 - Análise de sensibilidade e rank de sensibilidade dos parâmetros em relação à simulação da produção de sedimentos diária na bacia do Taboão, considerando a estatística <i>p-Value e</i> ; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006).....	232
Tabela 44 - Intervalo de variação, valores iniciais e valores calibrados dos parâmetros incluídos no processo de calibração do modelo SWAT, para um passo de tempo mensal e diário.....	233
Tabela 45 - Estatísticas de desempenho do modelo SWAT para a simulação da produção de sedimentos, no período de calibração (2013 e 2015) e de verificação (2014), considerando um passo de tempo mensal e diário	234
Tabela 46 - Estatísticas da produção de sedimentos anual simulada pelo modelo SWAT para a bacia do Taboão, considerando o período de 2013 a 2015.....	244
Tabela 47- Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos	304

LISTA DE ABREVIATURAS E SIGLAS

- ABNT:** Associação Brasileira de Normas Técnicas
- ADCP:** *Acoustic Doppler Current Profiler*
- ADJ_PKR:** fator de ajuste da taxa de pico para o aporte de sedimentos na sub-bacia
- AGRL:** código usado para indicar uso do solo tipo agricultura genérica – cultivo anual
- ALPHA_BF:** constante de recessão do escoamento de base
- ALPHA_BNK:** é a constante de recessão do escoamento de base para as margens do canal
- ANFIS:** *Adaptative Network based Fuzzy Inference Systems*
- ANION_EXCL:** porosidade do solo em uma dada camada
- ANSWERS:** modelo Areal Nonpoint Source Watershed Response Simulation
- BIOMIX:** eficiência biológica
- BLAI:** índice máximo de área foliar potencial da cultura
- CANMX:** quantidade máxima de água da chuva interceptada pela vegetação plenamente desenvolvida, disponível para evaporar sem atingir o solo (mm)
- CH_COV1:** fator de erodibilidade do canal
- CH_COV2:** fator de cobertura vegetal do canal
- CH_K2 e CH_K1:** condutividade hidráulica efetiva do canal principal e tributários, respectivamente (mm/h)
- CH_N2 e CH_N1:** coeficiente de rugosidade de Manning do canal principal e tributários, respectivamente
- CLAY:** porcentagem de argila em uma dada camada do solo (%)
- CN2:** valor inicial da Curva Número do escoamento superficial para a condição de umidade II (solo úmido)
- CRNA:** modelos de combinações de redes neurais artificiais
- CSS:** concentração de sedimentos suspensos
- DEEPST:** profundidade inicial da água no aquífero profundo (mm)
- DEWPT:** média diária do ponto de orvalho para cada mês (°C)
- Ea(50):** erro absoluto mediano ou (percentil 50% do erro)
- Ea(95):** erro absoluto não ultrapassado com frequência 95% ou percentil 95% do erro
- Ea(Max):** erro absoluto máximo
- EaM:** erro absoluto médio
- EMBRAPA:** Empresa Brasileira de Pesquisa Agropecuária
- EPCO:** fator de crescimento da cultura
- ERODMO:** fator de erodibilidade do canal, para cada um dos 12 meses do ano
- ES:** escoamento superficial
- ESCO:** fator de compensação da evaporação do solo
- Estatística-t (t-Stat):** estatística que indica uma medida da sensibilidade dos parâmetros na análise de sensibilidade realizada com o SWAT-CUP
- ET:** evapotranspiração real na bacia (mm)
- EUA:** Estados Unidos da América
- EUROSEM:** modelo EUROpean Soil Erosion Model
- EWMA:** média móvel das chuvas passadas, ponderada exponencialmente

Fator-p (*p-factor*): porcentagem dos dados medidos delimitadas pela incerteza de predição de 95% (95PPU)

Fator-r (*r-factor*): espessura média da banda 95PPU dividida pelo desvio padrão dos dados medidos

FILTERW: largura da borda de campo de filtros em tira (m)

FRSE: código usado para indicar uso do solo tipo floresta perene

GLUE: Probabilidade Generalizada da Estimativa de Incerteza (*Generalized Likelihood Uncertainty Estimation*)

GW_DELAY: regula o tempo de recarga do aquífero, representando o tempo necessário para a água atravessar a camada imediatamente abaixo da zona de raízes até chegar ao aquífero superficial (dias)

GW_REVAP: coeficiente que controla o fluxo de água da zona saturada para a não saturada

GWQ: escoamento subterrâneo (mm)

GWQMN: profundidade do aquífero para escoamento de base (mm)

GX: Gleissolo Háplico

HRU: unidades de resposta hidrológica (*Hydrologic Response Units*)

HRU_SLP: média da declividade de cada HRU (% ou m/m)

HYDGRP: grupos de saturação (A, B, C ou D)

IBGE: Instituto Brasileiro de Geografia e Estatística

IGRO: parâmetro do SWAT que indica se existe planta em desenvolvimento no solo no primeiro dia do primeiro ano considerado para a simulação com o modelo SWAT

IID: igual incremento de descarga. Método de divisão da seção de um rio para realização medições e coleta de amostras de água

III: igual incremento de largura. Método de divisão da seção de um rio para realização medições e coleta de amostras de água

IPH: Instituto de Pesquisas Hidráulicas da

KINEROS2: modelo KINematic EROsion Simulation 2

LAI_INIT: índice de área foliar inicial (m²/m²)

LAT_SED: concentração de sedimentos no escoamento subsuperficial, que contribui para o canal principal (mg/L)

LAT_TTIME: tempo do escoamento lateral (dias)

LATQ: escoamento subsuperficial (mm)

LISEM: modelo Limburg Soil Erosion Model

LVd1: Latossolo Vermelho Distrófico típico

LVd2: Latossolo Vermelho Distrófico

LVdf1: Latossolo Vermelho Distroférico típico

LVdf2: Latossolo Vermelho Distroférico

LVdf3: Latossolo Vermelho Distroférico típico, A moderado

MCMC: Métodos de Monte Carlo via Cadeias de Markov (*Markov chain Monte Carlo*)

MNT: modelo numérico do terreno

MP: média ponderada pelo inverso da distância

MS: média simples

MUSLE: Equação Universal de Perdas de Solo Modificada

NA: indica nível de água

NLAYERS: número de camadas o perfil do solo

nmi: número de neurônios utilizados na camada intermediária (interna) dos modelos de RNAs do tipo *feedforward*

NS: coeficiente de eficiência de Nash-Sutcliffe

NVef: Nitossolo Vermelho Eutroférico

OV_N: coeficiente de rugosidade de Manning para escoamento na superfície

P: precipitação (mm)

ParaSol: Solução de Parâmetros (*Parameter Solution*)

PAST: código usado para indicar uso do solo tipo pastagem

PBIAS: Porcentagem bias (%)

PCCSKW: coeficiente de assimetria para a precipitação diária por mês

PCPD: média mensal de dias de precipitação no mês (dias)

PCPMM: média mensal da precipitação total (mm)

PCPSTD: desvio padrão para a precipitação diária do mês (mm)

PERC: água percolada no solo, que recarrega o aquífero.

PET: evapotranspiração potencial (mm)

PR_W1: probabilidade de dias úmidos seguidos de dias secos para o mês

PR_W2: probabilidade de dias úmidos seguidos de dias úmidos para o mês

PRF: fator de ajuste da taxa de pico para o aporte de sedimentos no canal principal;

PS_{1seg}: produção de sedimentos produzida a cada segundo do intervalo de 10 min

PS_{ano}: produção de sedimentos anual

PS_{dia}: produção de sedimentos diária

PS_{mês}: produção de sedimentos mensal

PSO: Método do enxame de partículas (*Particle Swarm Optimization*)

PS_{obs}: produção de sedimentos observada (ton)

PS_{sim}: produção de sedimentos simulada (ton)

PVG: posto pluviométrico ou pluviógrafo

Q_{obs}: vazão observada (m³/s)

Q_{sim}: vazão simulada (m³/s)

Qss: descarga de sedimentos

quan: abreviatura usada no nome dos modelos de RNAs desenvolvidos para preenchimento da turbidez. Indica a quantidade de registros usados na série de treinamento do modelo de RNA

R: coeficiente de correlação ou coeficiente de Pearson

R²: coeficiente de determinação

RAINHHMX: valor máximo de 0,5 h de chuva para o mês (mm)

RCHRG_DP: regula a percolação da zona de raízes para o aquífero profundo

Reg: número de dados utilizados na série de treinamento dos modelos de RNAs

Rep: número de repetições iniciais executadas durante o treinamento dos modelos de RNAs

REVAPMN: profundidade limite de água no aquífero raso para ocorrer o revap ou percolação (mm)

RGB: *Red, Green e Blue* (composição)

RLe: Neossolo Litólico Eutrófico

RMSE: raiz quadrada do erro quadrático médio

RNA: rede neural artificial

ROCK: porcentagem de pedras em uma dada camada do solo (%)

RSDIN: material residual depositado nos primeiros 10 mm do solo (Kg/ha)

RSR: Coeficiente de desvio padrão das observações

RYbe: Neossolos Flúvicos Tb Eutróficos

SAND: porcentagem de areia em uma dada camada do solo (%)

SCS: *Soil Conservation Service*

SDR: taxa de entrega de sedimentos

Sensor OBS: Optical backscatter point sensor

SF: sedimento fino

SFTMP: temperatura da precipitação (°C)

SG: sedimento grosso

SHALLST: profundidade inicial da água no aquífero raso (mm)

SILT: porcentagem de silte em uma dada camada do solo (%)

SLOPE: rampa média adotada para todas as HRU's em uma sub-bacia (m)

SLSOIL: comprimento da declividade para o escoamento subsuperficial (m)

SLSUBBSN: comprimento de rampa médio para a sub-bacia (m)

SN: sedimento normal

SOL_ALB: albedo em uma dada camada do solo

SOL_AWC: capacidade de água no solo na camada do solo

SOL_BD: densidade aparente em uma dada camada do solo (mg/m³ ou g/cm³)

SOL_CBN: carbono orgânico em uma dada camada do solo (%)

SOL_K: condutividade hidráulica saturada na camada do solo (mm/h)

SOL_Z: profundidade da camada de solo (mm)

SOL_ZMX: profundidade máxima da raiz (mm)

SOLARAV: média diária de radiação solar para cada mês (MJ/m²/dia)

SPCON: parâmetro linear para o cálculo da quantidade máxima de sedimentos que pode estar reentrando durante o aporte de sedimentos no canal (m/s)

SPEXP: parâmetro exponencial para o cálculo da reentrada de sedimentos no canal

SRTM: *Shuttle Radar Topography Mission*

SUFI-2: Sequencial de Montagem das Incertezas (*Sequential Uncertainty Fitting algorithm*)

SURLAG: coeficiente de atraso (lag) do escoamento superficial (h)

SURQ: escoamento superficial (mm)

SW: água armazenada no solo nas HRUs

SWAT: modelo Soil and Water Assessment Tool

SWAT-CUP: *SWAT Calibration and Uncertainty Procedures*

T ou Turb: indica turbidez

Tc: tempo de concentração

TMPMN: média mensal de temperatura mínima diária (°C)

TMPMX: média mensal de temperatura máxima diária (°C)

TMPSTDMN: desvio padrão para a temperatura mínima diária de cada mês (°C)

TMPSTDMX: desvio padrão para a temperatura máxima diária de cada mês (°C)

TSS: sólidos suspensos total

UFRGS: Universidade Federal do Rio Grande do Sul

URHD: código usado para indicar uso do solo tipo área residencial de alta densidade

URLD: código usado para indicar uso do solo tipo área residencial de baixa densidade

USGS: Serviço Geológico dos Estados Unidos (*United States Geological Survey*)

USLE: Equação Universal de Perdas de Solo

USLE_C: valor mínimo do fator C de cobertura vegetal da USLE

USLE_K: fator de erodibilidade do solo da USLE $[(0,013\text{ton/m}^2/\text{hr})/(\text{m}^3/\text{ton}/\text{cm})]$.

USLE_P: fator P de práticas de suporte da USLE

UTRN: código usado para indicar uso do solo tipo estradas

Valor-p (*p-Value*): determina a significância da sensibilidade na análise de sensibilidade realizada com o SWAT-CUP

WATR: código usado para indicar uso do solo tipo água

WEPP: modelo Water Erosion Prediction Project

WESP: modelo Watershed Erosion Simulation Program

WDAV: média diária da velocidade do vento para cada mês (m/s)

WYLD: produção de água ou volume de água propagado pelo canal (mm).

SUMÁRIO

1	APRESENTAÇÃO.....	26
1.1	Introdução.....	26
1.2	Objetivo geral.....	32
1.2.1	Etapas necessárias ao desenvolvimento do trabalho.....	32
1.3	Hipóteses.....	33
2	REVISÃO DE LITERATURA.....	34
2.1	Erosão, transporte e deposição de sedimentos.....	34
2.1.1	O papel da erosão na dinâmica da produção de sedimentos.....	34
2.1.2	Transporte e deposição dos sedimentos.....	37
2.1.3	Caracterização dos sedimentos em bacias rurais.....	39
2.2	Monitoramento da concentração de sedimentos.....	40
2.3	A turbidez como medida substituta da concentração de sedimentos suspensos (CSS).....	43
2.3.1	Teoria da óptica.....	44
2.3.2	Fatores que influenciam o sinal identificado por um sensor óptico.....	45
2.3.2.1	Concentração de sedimentos suspensos (CSS).....	45
2.3.2.2	Tamanho da partícula de sedimento transportado.....	49
2.3.2.3	Forma e rugosidade da partícula de sedimento transportado.....	55
2.3.2.4	Cor e composição mineralógica da partícula de sedimento transportado.....	56
2.3.2.5	Características ópticas e geométricas do sensor utilizado no monitoramento.....	57
2.3.2.6	Presença de bolhas, gases e outros componentes na coluna de água.....	59
2.3.2.7	Processos de floculação, agregação e turbulência.....	61
2.3.3	Aplicações de sensores ópticos como medida indireta da CSS: o cenário brasileiro.....	65
2.4	A modelagem como ferramenta para análise da dinâmica hidrossedimentológica.....	69
2.4.1	Modelos de funções explícitas para determinação da concentração de sedimentos suspensos (CSS).....	73
2.4.2	As redes neurais artificiais (RNAs) e a previsão da concentração de sedimentos suspensos (CSS).....	75
2.4.3	A modelagem dos processos hidrossedimentológicos com o <i>Soil And Water Assessment Tool</i> (SWAT).....	81
2.4.3.1	Análise de sensibilidade, calibração e verificação.....	86
2.4.3.2	O SWAT e a modelagem hidrossedimentológica: alguns estudos brasileiros e seus apontamentos.....	99
3	MATERIAIS E MÉTODOS.....	110
3.1	Localização da área de estudo e características climáticas.....	110
3.2	Caracterização das classes de uso do solo.....	112
3.3	Caracterização das classes de tipo de solo, variação altimétrica e declividade.....	115

3.4	Monitoramento do nível de água e determinação da vazão.....	120
3.5	Monitoramento da turbidez	121
3.6	Concentração de sedimentos suspensos (CSS).....	122
3.7	Modelos de RNAs para preenchimento de falhas nos dados de nível de água	124
3.8	Modelos de RNAs para preenchimento de falhas nas informações de turbidez	128
3.9	Modelos de RNAs e funções explícitas para previsão da CSS	129
3.9.1	Subdivisão dos dados amostrais	129
3.9.2	Modelos de funções explícitas.....	130
3.9.3	Modelos baseados em RNAs.....	131
3.9.4	Estatísticas de desempenho dos modelos	137
3.10	Erosividade da chuva e produção de sedimentos diária, mensal e anual	138
3.11	Simulação hidrossedimentológica com o modelo SWAT.....	139
3.11.1	Planos de informação requeridos pelo modelo SWAT: mapas de uso do solo, tipo de solo, modelo numérico do terreno e classes de declividade	140
3.11.2	Características físico-hídricas do solo requeridas pelo modelo SWAT	142
3.11.3	Precipitação e demais parâmetros relacionados a essa variável, requeridos para simulação do modelo SWAT.....	144
3.11.3.1	Preenchimento de falhas nos dados horários de precipitação.....	146
3.11.4	Temperatura máxima e mínima do ar, radiação solar, velocidade do vento, umidade relativa do ar e temperatura do ponto de orvalho	150
3.11.5	Análise de sensibilidade, calibração e verificação do modelo SWAT	151
4	RESULTADOS E DISCUSSÕES.....	156
4.1	Análise das estatísticas descritivas entre nível de água, turbidez e CSS.....	156
4.5	Estimativa dos dados de CSS: análise das funções explícitas entre nível de água, turbidez e CSS	187
4.6	Estimativa da CSS utilizando RNAs sem emprego de recursos para evitar o superajustamento (Modelo_0): modelo Nível de água – Turbidez x CSS	194
5	CONCLUSÕES E RECOMENDAÇÕES	248
	REFERÊNCIAS	252
	ANEXO A - PRINCIPAIS EQUAÇÕES PARA SIMULAÇÃO DOS PROCESSOS HIDROSSEDIMENTOLÓGICOS NO MODELO SWAT.....	294
	APÊNDICE A: DESCRIÇÃO DE ESTUDOS QUE UTILIZARAM RNAs PARA CÁLCULOS HIDROSSEDIMENTOLÓGICOS	304

1 APRESENTAÇÃO

1.1 Introdução

Ao longo do tempo, a ação antrópica tem alterado as paisagens naturais e instigado uma série de consequências sobre o meio ambiente, algumas de caráter irreversível. Entre as implicações mais graves destaca-se a degradação dos solos por processos erosivos, com subsequente deterioração das águas pelo carreamento de sedimentos aos corpos hídricos, especialmente àqueles associados a poluentes e a contaminantes.

De fato, nesse último século, o processo de erosão dos solos, o transporte e o depósito de sedimentos nos corpos hídricos foi muito significativo, provocando alterações na dinâmica hidrossedimentológica, em escala local e global (MORGAN, 2005). Diante desse cenário, a questão dos sedimentos e os problemas deles advindos representam um grande desafio para o gerenciamento e a conservação dos recursos hídricos.

Esses problemas, tanto nas regiões de clima temperado quanto naquelas tropicais, podem resultar, sobretudo, de eventos moderados, mas que, por outro lado, apresentam ocorrência recorrente e frequente. Na realidade, essa influência irá depender não somente da magnitude do evento em si, mas também, da presença de condições favoráveis ao desenvolvimento dos processos erosivos. Por isso, é necessário um conhecimento profundo de como ocorrem esses processos e de quais fatores são determinantes para esses acontecimentos (MORGAN, 2005).

Uma forma de se buscar essa compreensão consiste no monitoramento de variáveis relacionadas aos processos hidrossedimentológicos, entre as quais: a precipitação, a vazão e a concentração de sedimentos suspensos (CSS). Informações sobre a estimativa da CSS nos rios, em específico, são primordiais ao adequado gerenciamento das bacias hidrográficas, na proporção em que são elementos bases para o diagnóstico e a análise das consequências do uso e do manejo do solo; para a avaliação do fluxo de poluentes adsorvidos aos sedimentos; para o estudo da erosão na bacia e; para a implementação efetiva de medidas para a minimização dos problemas decorrentes da presença desses sedimentos.

Tradicionalmente, a determinação da CSS é realizada através da coleta de amostras físicas e de posteriores análises laboratoriais. Entretanto, esse processo é oneroso e consome grande quantidade de tempo, recursos humanos e financeiros; o que dificulta a obtenção de séries históricas. Tais características concorrem, por sua vez, para dificuldades em torno da antecipação das consequências de determinadas ações de manejo e utilização dos solos. Nessa

conjuntura, a modelagem ambiental desponta como uma ferramenta bastante útil e de custo relativamente acessível se comparada a trabalhos e pesquisas experimentais; viabilizando a simulação e a investigação das condições atuais, e também, de possíveis panoramas futuros. Auxiliando, ainda, na escolha das melhores alternativas de planejamento e das intervenções mais adequadas para cada uma das situações simuladas.

Convém salientar, entretanto, que a base de uma boa modelagem reside, justamente, em seus dados de monitoramento, que são fundamentais ao desenvolvimento dos processos de calibração e de verificação¹ de um dado modelo, e para a parametrização de simulações de cenários atuais e futuros. Infelizmente, as séries relacionadas à sedimentologia (entre as quais a CSS) nas bacias hidrográficas brasileiras são muito limitadas e, muitas vezes, não representam os períodos em que comumente os sedimentos são produzidos e transportados, a saber: os períodos de cheias. Por isso, pesquisadores têm desenvolvido métodos alternativos que relacionam a CSS a outras variáveis, buscando a determinação indireta do transporte de sedimentos ao longo do tempo (BAYRAM, KANKAL e ÖNSOY, 2012; BAYRAM et al. 2014). Entre os métodos mais utilizados estão as relações vazão-CSS (GAO e JOSEFSON, 2012; SU, LU e HONG, 2013, TÓTH e BÓDIS, 2015) e as tecnologias alternativas de monitoramento, como os sensores ópticos (HARRINGTON e HARRINGTON 2013; SHELLNBARGER, WRIGHT e SCHOELLHAMER, 2013; HAIMAN et al., 2014; TANANAEV e DEBOLSKIY, 2014).

Construir redes de monitoramento mais eficientes é, pois, uma necessidade premente para hidrólogos, projetistas e gerenciadores de bacias hidrográficas. Talvez, semelhantes melhorias perpassem pela adoção de tecnologias alternativas de monitoramento, que viabilizem a criação de séries contínuas, como é o caso dos sensores de turbidez.

Contudo, é preciso destacar que a estimativa do transporte de sedimentos não depende unicamente das vazões no rio, mas também, de inúmeras características relacionadas ao próprio escoamento, que são variáveis ao longo do tempo (AFAN et al., 2015) e resultantes da interação de processos complexos e não lineares (BOUKHRISSA et al., 2013; AFAN et al., 2015). Em razão disso, a abordagem clássica da hidromecânica, representada pelas relações lineares e

¹ Para efeitos de melhor compreensão do texto é importante destacar, que ao longo dessa tese, utilizou-se o termo “verificação” para referir-se ao procedimento de teste aplicado a um modelo (SWAT ou RNA, no caso desse estudo), com o objetivo de avaliar seu desempenho para um conjunto de dados não empregado no processo de calibração (modelo SWAT) ou de treinamento (modelos de RNAs). Já o termo “validação” é empregado para definir o conjunto de dados utilizados para o procedimento de “validação cruzada” (ou “Validação por Reamostragem”, para a nova metodologia aplicada nessa pesquisa), que tem por finalidade avaliar o erro, ao longo do treinamento de uma RNA, utilizando uma série de dados não empregada para o treinamento; de modo a definir o momento ideal de parada do treinamento.

equações simplificadas CSS-vazão, nem sempre é suficiente para a adequada modelagem dos processos sedimentológicos. Da mesma forma, a desconsideração ou a representação inadequada dos fatores que interferem nas leituras dos sensores ópticos pode limitar a aplicabilidade dessa tecnologia, resultando em curvas de calibração não confiáveis e, conseqüentemente, em modelos não aplicáveis a condições relativamente diferentes daquelas para as quais foram desenvolvidos. Os fatores que afetam a resposta dos sensores estão relacionados à partícula de sedimento transportada, às características ópticas e geométricas do instrumento, à presença de determinados componentes na coluna de água e às características do escoamento (DOWNING, 2006; SARI, CASTRO e KOBIYAMA, 2015).

Desse modo, compreender como esses sensores de turbidez respondem às diferentes características ambientais e climatológicas, presentes em bacias hidrográficas brasileiras, é fundamental para a implantação dessas tecnologias de baixo custo no Brasil. E, obviamente, como a conversão das informações de turbidez em dados de CSS não é uma tarefa simples, encontrar ferramentas que auxiliem essa conversão é também uma necessidade premente na implantação de eficientes sistemas de monitoramento contínuo.

Em razão de tais particularidades, a adoção da turbidez como tecnologia substituta para a determinação da CSS faz surgir uma nova questão junto aos pesquisadores: como assegurar que a conversão entre turbidez e CSS realize-se de forma adequada, já que muitos fatores afetam as leituras desses sensores, fazendo com que essa relação de conversão não seja linear?

Há que se considerar, ainda, que a não continuidade e as falhas nas séries de dados (precipitação, turbidez, vazão, CSS, etc.) representam um grande problema para a efetivação de estudos de modelagem, assim como para o planejamento e o gerenciamento dos recursos hídricos em uma bacia hidrográfica. Tais problemas são, comumente, uma decorrência de falhas na gravação dos dados de campo, problemas de transmissão, equipamentos com defeito e, até mesmo, devido a outros erros gerados pela própria equipe de campo por ocasião da coleta (PASHOVA, KOPRINKOVA-HRISTOVA e POPOVA, 2013; USTOORIKAR e DEO, 2008).

Quando o intervalo das falhas é pequeno, a interpolação linear pode ser suficiente para a recuperação das informações ausentes. No entanto, quando existe um período longo de valores falhos, especialmente quando padrões irregulares estão presentes (ex: quando ocorrem eventos), a interpolação linear pode não ser o método mais acertado para a efetivação do preenchimento (LEE e PARK, 2016).

Uma solução para essas problemáticas pode estar no emprego de técnicas de preenchimento de falhas e de conversão de dados, que permitam o aprendizado do modelo a

partir da variação de outros dados monitorados no local; melhorando, com isso, a capacidade de generalização desses modelos para novas aplicações. Estão incluídas nesse grupo as Redes Neurais Artificiais (RNAs), em virtude de sua grande capacidade de aprendizado, generalização e de organização de dados em modelos não-lineares. As RNAs são modelos empíricos que imitam o funcionamento do cérebro humano, possuindo características em comum com as redes neurais biológicas, como por exemplo, as habilidades de adaptação, de aprendizado e de generalização (ASCE, 2000).

Essas redes têm sido utilizadas para o desenvolvimento de modelos de preenchimento de falhas e previsão de dados de precipitação, de nível de água e de vazão (LUCIO et al., 2007; NG, PANU e LENNOX, 2009; DASTORANI et al., 2010; NKUNA e ODIYO, 2011; ALMEIDA e ALMEIDA, 2012; KASHANI e DINPASHOH, 2012; MWALE, ADELOYE e RUSTUM, 2012; PASHOVA et al., 2013; DEPINÉ et al., 2014; DOUNIA et al., 2014; ZAW e HARTMUT, 2014; LONDHE et al., 2015; MOHAMMED e MOLLAH, 2015; SHIAU e HSU, 2016). Mais recentemente, modelos baseados em RNAs (ou associados a elas) também têm atraído pesquisadores da área de sedimentologia (NOURANI e KALANTARI, 2010; TALEBIZADEH et al., 2010; MELESSE et al., 2011; BAYRAM, KANKAL e ÖNSOY, 2012; MUSTAFA et al., 2012; NOURANI, KALANTARI e BAGHANAM, 2012; SINGH et al., 2012, 2013; BOUKHRISSA et al., 2013; LAFDANI, NIA e AHMADI, 2013; BAYRAM et al., 2014; NOURANI et al., 2014; AFAN et al., 2015), demonstrando que essas redes podem ser uma alternativa viável para a predição da CSS.

Não obstante, as RNAs não são bons extrapoladores e, por isso, a amostra de treinamento, que originará o modelo, deverá cobrir todo o domínio desejado (FREEMAN e SKAPURA, 1991) para os dados que serão simulados. Esse fator, muitas vezes, limita a aplicação dessas redes, na medida em que exige grande quantidade de registros de dados para treinamento e verificação da generalização (capacidade da RNA em prever condições futuras diferentes da examinada no treinamento); condição essa impraticável para os locais em que o monitoramento é pouco abrangente. No Brasil, infelizmente, essa realidade é bastante comum para o monitoramento das variáveis sedimentológicas.

Esse cenário de escassez de dados sedimentológicos, observado em diversas regiões do país e mesmo do mundo, embasa a necessidade de desenvolvimento de modelos que possam ser aplicados em locais com limitações no monitoramento e que, ao mesmo tempo, utilizem como variáveis de entrada informações obtidas a baixo custo. Por certo, o desenvolvimento de metodologias que permitam o treinamento de RNAs com menor quantidade de dados, e que

sejam pouco onerosas, precisas e de fácil utilização, possibilitará redes de monitoramento mais eficientes e a disponibilização de séries sedimentológicas mais amplas, estendidas pela utilização dos modelos.

Nesse contexto, esta pesquisa busca desenvolver modelos de RNAs para: i) realizar o preenchimento de falhas nos dados monitorados de precipitação na bacia do Taboão, a partir de informações pluviométricas de postos vizinhos; ii) efetuar o preenchimento de dados falhos de nível de água na bacia do Taboão, com base em entradas de chuva média e de níveis de água em bacias embutidas e/ou adjacente à bacia do Taboão; iii) realizar o preenchimento nas falhas dos dados de turbidez na bacia do Taboão, empregando como entrada informações de nível de água na bacia e ainda; iv) estimar a CSS na bacia do Taboão, utilizando como entradas dados de turbidez e de nível de água.

É importante acrescentar, igualmente, que grande parte dos modelos em uso na atualidade, pode estar subestimando ou superestimando os resultados da dinâmica hidrossedimentológica, considerando a sua não adequabilidade às condições brasileiras, e a baixa disponibilidade de dados monitorados para a sua calibração e verificação. Sendo assim, é extremamente relevante monitorar essas variáveis e desenvolver melhores sistemas de monitoramento, na tentativa de adequar à realidade brasileira os modelos existentes, na maioria desenvolvido em outros países, com condições ambientais (clima, hidrologia, solos, etc.) muito diferentes.

Essa adequação é fundamental pois, a utilização da modelagem como ferramenta de análise do comportamento da dinâmica hidrossedimentológica permite entender e conhecer os efeitos das alterações do uso e do manejo do solo e assim, prevenir os impactos dos sedimentos nos recursos hídricos.

Entre os modelos disponíveis para a modelagem dessa dinâmica está o modelo SWAT (*Soil and Water Assessment Tool*). Ele tem sido utilizado em diferentes países (sobretudo nos Estados Unidos e países da União Europeia) para a predição da vazão e da produção e do transporte de sedimentos e de nutrientes; para investigação de alterações no uso do solo e para a simulação de cenários futuros em termos de alterações do uso e do manejo do solo, e também, de variações ocasionadas por mudanças climáticas (GASSMAN et al., 2007). Sendo que os resultados obtidos por intermédio de tais simulações, geralmente, mostram-se satisfatórios e promissores em sua aplicabilidade e consistência. O modelo SWAT já foi aplicado, por Depiné (2014), na bacia hidrográfica dessa pesquisa para estimativa da vazão, com ótimos resultados, e por isso, esse foi o modelo adotado nessa pesquisa para simulação dos processos hidrossedimentológicos.

Convém destacar ainda, que esse estudo foi ao encontro das pretensões da linha de pesquisa “Estudo e modelagem dos processos hídricos: geração de vazão e sedimentos em pequenas bacias”— do Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul (IPH/UFRGS)—, por se tratar de uma temática fundamental, recente e tão necessária ao entendimento da influência de fatores intervenientes nos processos hidrossedimentológicos na bacia hidrográfica do rio Potiribu e suas sub-bacias, entre as quais a bacia do Taboão (monitorada nesse estudo).

A bacia do rio Potiribu, localizada sobre o derrame basáltico sul-rio-grandense, é monitorada desde 1989 pelo IPH e está situada sobre uma região com problemas de escoamento superficial e de erosão do solo, com presença de ravinas e voçorocas (CASTRO, CHEVALLIER e SILVEIRA, 1993; CASTRO, 1996; CASTRO et al., 1999; VIERO, 2004), ocasionadas, sobretudo, pelo desenvolvimento da agricultura intensiva. Viero (2004) mapeou 83 voçorocas distribuídas homogeneamente na bacia do Taboão, sendo que 45 delas encontravam-se ativas na época do estudo e 10 já estavam recuperadas.

A introdução do sistema de plantio direto na década de 90 atenuou os processos erosivos e o aporte de sedimentos aos mananciais hídricos. Entretanto, como observado por Viero (2004), em muitos locais a erosão ainda persiste, especialmente quando ocorrem precipitações de elevada magnitude. De fato, as voçorocas estão relacionadas a distintas formas de uso do solo, sendo que em 67,5% dos casos, o solo é cultivado através da prática do plantio direto, em 23% deles, as voçorocas ocorrem em locais utilizados para criação de gado, e em 9,5% dos casos, as voçorocas situam-se em áreas onde se desenvolvem campos (VIERO, 2004).

Por certo, perante esse cenário, a compreensão dos processos hidrossedimentológicos na bacia e o monitoramento das variáveis relacionadas aos sedimentos, pode auxiliar na adequação das práticas de uso e de manejo do solo; orientando a escolha de medidas mitigadoras dos problemas advindos da erosão do solo e da produção de sedimentos. A quantificação dos sedimentos presentes nos corpos hídricos na bacia do Taboão é, portanto, o passo inicial para a prevenção e o controle dos problemas causados pelo transporte e deposição desses sedimentos; assim como o é também, para o desenvolvimento da modelagem hidrossedimentológica e para os estudos de planejamento e gerenciamento da bacia.

1.2 Objetivo geral

Analisar a aplicação do modelo SWAT na previsão da produção de sedimentos em uma bacia hidrográfica no Noroeste do Rio Grande do Sul (Brasil), para os anos de 2013 a 2015, utilizando séries contínuas de CSS, obtidas pelo emprego de RNAs e dados de nível de água e de turbidez.

1.2.1 Etapas necessárias ao desenvolvimento do trabalho

- Desenvolver modelos de RNAs para estabelecer uma relação adequada entre a turbidez monitorada por um sensor óptico, o nível de água no rio e a CSS, objetivando a obtenção de séries contínuas de CSS;
- Analisar o desempenho dos modelos de RNAs desenvolvidos em relação às funções lineares, linearizáveis e não-linearizáveis, comumente empregadas (funções nível de água-CSS; turbidez-CSS e turbidez-nível de água-CSS) para a previsão da CSS;
- Desenvolver modelos de RNAs para o preenchimento dos dados de precipitação horária obtidos dos pluviógrafos, instalados na bacia hidrográfica do Taboão, para serem utilizados na simulação hidrossedimentológica com o modelo SWAT;
- Desenvolver modelos de RNAs para o preenchimento dos dados de nível de água na bacia do Taboão, utilizando dados de precipitação e níveis de água nas bacias adjacentes e/ou embutidas na bacia do Taboão;
- Desenvolver modelos de RNAs para preenchimento dos dados de turbidez na bacia do Taboão, empregando dados de nível de água monitoradas no exutório da bacia;
- Realizar análise de sensibilidade dos parâmetros relacionados aos processos hidrossedimentológicos na bacia do Taboão, utilizando o SWAT-CUP (*SWAT Calibration and Uncertainty Procedures*);
- Calibrar e verificar o modelo SWAT para estimativa dos processos hidrossedimentológicos na bacia hidrográfica do Taboão, utilizando séries contínuas de vazão (obtidas por curva-chave) e de produção de sedimentos (obtidas através do emprego de modelos de RNAs);
- Simular com o modelo SWAT a produção de água e de sedimentos na bacia do Taboão para o cenário atual de uso, cobertura e manejo do solo;

- Avaliar a distribuição espacial da produção de água e de sedimentos na bacia do Taboão para o cenário atual de uso, cobertura e manejo do solo.

1.3 Hipóteses

Essa pesquisa foi conduzida tendo por base duas hipóteses básicas:

- I. A adequada correspondência entre os valores de CSS simulados pela RNA e aqueles monitorados na bacia analisada torna esse modelo de RNA uma promissora ferramenta para a estimativa de séries contínuas de CSS, que podem ser utilizadas para calibração e verificação de modelos hidrossedimentológicos;
- II. Com o modelo SWAT calibrado e verificado para a bacia do Taboão é possível simular diferentes cenários de uso e cobertura do solo, bem como de manejo do solo, avaliando quais são as melhores alternativas para o adequado planejamento e gerenciamento dos recursos naturais da bacia.

2 REVISÃO DE LITERATURA

Esse item tem por objetivo oferecer suporte à discussão das relações existentes entre os usos, a cobertura e o manejo do solo, as características geomorfológicas e os processos hidrossedimentológicos. São descritos também, conhecimentos fundamentais em relação às medições do transporte de sedimentos nos rios.

Traz-se, ainda, conceitos-chaves acerca do emprego da turbidez como tecnologia substituta (aos tradicionais métodos de coletas de sedimentos e posterior análise laboratorial) na determinação da CSS, e particularidades do emprego das RNAs na determinação de relações não lineares entre a turbidez e a CSS, ocasião em que se apresentam estudos que utilizaram as RNAs para estimar variáveis sedimentológicas.

Esse capítulo discorre, igualmente, sobre a modelagem como alternativa para a estimativa da erosão, do transporte e da deposição de sedimentos; com especial destaque ao modelo SWAT. Para esse último são apresentados estudos que empregaram o modelo para determinar os processos hidrossedimentológicos em bacias hidrográficas brasileiras.

2.1 Erosão, transporte e deposição de sedimentos²

2.1.1 O papel da erosão na dinâmica da produção de sedimentos

Os sedimentos podem ser conceituados como fragmentos de rochas e de solo, desagregados pelo processo de intemperismo ou pela ação da erosão. Compreendem, em sua maioria, detritos minerais, embora exista, ainda, uma quantidade significativa de partículas orgânicas. Atualmente também tem grande importância os sedimentos oriundos de atividades antrópicas, bem como os materiais resultantes de ambientes naturais altamente impactados pela ação humana (PERRY e TAYLOR, 2007).

Quando transportados pelo escoamento no interior da calha fluvial, os sedimentos recebem o nome de sedimentos fluviais (EDWARDS e GLYSSON, 1999), constituindo-se em uma importante fonte de transferência de nutrientes, de contaminantes e de outros materiais

² Escrito com base em:

SARI, V.; POLETO, C.; CASTRO, N.M. dos R. Caracterização dos processos hidrossedimentológicos em bacias rurais e urbanas. **Enciclopédia Biosfera**, v. 9, n. 16, p. 596-624, 2013.

sólidos às jusantes fluviais, aos estuários e aos ambientes costeiros (HUDSON-EDWARDS, 2007).

Os processos erosivos, responsáveis pela produção desses sedimentos, são processos naturais, decorrentes da presença de condições favoráveis a seu desenvolvimento (fatores naturais), sendo acelerados, em larga escala, pelas atividades antrópicas (CARVALHO, 2008; WMO, 2003, MORGAN, 2005). Entre os fatores naturais enquadram-se: a meteorologia (precipitação, vento e degelo); a geologia (composição da rocha base e movimentos das placas tectônicas); a topografia (gradiente de declividade, comprimento e direção da rampa); as características do solo (morfologia, capacidade de infiltração, resistência à erosão, textura, estrutura, conteúdo de matéria orgânica, permeabilidade e fator de erodibilidade); a composição da superfície e; a cobertura vegetal (BONAN, 2002; CARVALHO, 2008; WMO, 2003).

As chuvas, em especial as grandes tempestades, afetam consideravelmente a erosão do solo, sendo sua influência sobre os processos erosivos dependente da quantidade, intensidade e duração da chuva, e ainda, do tamanho e da velocidade de queda da gota. Esses dois últimos elementos apresentam maior relevância no processo, já que determinam a energia cinética das gotas que impactam a superfície do solo, que em última instância, é a grande geradora da erosão em si (WMO, 2003). Portanto, tempestades intensas tendem a gerar gotas de chuva maiores, aumentando, com isso, o escoamento e o transporte de determinadas partículas; sendo que os danos advindos tendem a ser mais elevados quando essas tempestades forem breves. Já as chuvas mais leves e estendidas por longos períodos de tempo, apesar de gerarem um total pluviométrico maior, ocasionam erosões menos significativas (BONAN, 2002).

A erosão do solo também aumenta com a elevação do gradiente de declividade, até um determinado valor limite (gradiente crítico), a partir do qual deixa de sofrer elevação (WMO, 2003). Assim, solos situados em áreas de maior declividade tendem a produzir maior quantidade de sedimentos se comparados aos de áreas menos declivosas, sobretudo, quando manejados inadequadamente (MELLO, 2006). Isso porque, em regiões de declive a água escoar mais rapidamente, ocorrendo menor infiltração e, com isso, maior esforço sobre o terreno, provocando maior erosão. Por outro lado, as áreas mais planas tendem a receber os sedimentos erodidos dos locais de maior declive (BONAN, 2002; CARVALHO, 2008).

A presença de matéria orgânica e de argila melhora a estrutura do solo, aumentando sua capacidade de manter-se estruturado, o que, por consequência, reduz a erosão decorrente do impacto das gotas de chuva (WMO, 2003; MELLO, 2006). Baixas taxas de infiltração são responsáveis por maior escoamento e possibilidade de erosão, enquanto que as altas taxas geram

o contrário. Não obstante, a ocorrência ou não dessa erosão também estará relacionada à estrutura do solo (BONAN, 2002).

No controle da erosão é importante reconhecer ainda o relevante papel da cobertura vegetal que, ao atuar como uma camada protetiva do solo, minimiza os impactos causados pelas gotas de chuva e os efeitos da ação do vento próximo a sua superfície. Além disso, em razão da agregação do solo às raízes e liteiras, a vegetação facilita a infiltração da água precipitada e reduz a velocidade do escoamento superficial possibilitando, ao mesmo tempo, a melhoria das propriedades físicas, químicas e biológicas do solo (BONAN, 2002; WMO, 2003). Todavia, a proteção oferecida pela vegetação difere bastante em função de suas características (espécie, tamanho, índice de área foliar, etc.). Assim, uma floresta, por exemplo, apresenta maior eficiência na proteção do solo em comparação a uma vegetação do tipo rasteira (CARVALHO, 2008).

Adentrando na discussão do papel das atividades humanas nos processos erosivos, torna-se imprescindível reconhecer sua responsabilidade na aceleração da erosão, influenciando o tipo e a intensidade desses processos e exercendo efeitos positivos ou negativos sobre eles. De modo geral, a erosão tende a aumentar com o crescimento da população, uma vez que também aumentam o uso do solo e outras causas de erosão antrópica (CARVALHO, 2008). Entre as consequências decorrentes desses processos erosivos incluem-se: i) perdas de solo, de material orgânico e de nutrientes, provocando a redução da sua fertilidade e da sua profundidade de cultivo e, por consequência, afetando o crescimento das plantas; ii) aumento das cargas de sedimentos nos rios; iii) assoreamento de rios e reservatórios com agravamento dos problemas socioambientais (inundações, racionamento de água, etc.); iv) eutrofização dos lagos; v) diminuição da qualidade das águas; etc. (BONAN, 2002; CARVALHO, 2008).

Sendo assim, é evidente que o comportamento de uma bacia hidrográfica em relação aos sedimentos é bastante variável, dependendo, sobretudo, do tipo e do uso do solo, da cobertura vegetal, da declividade, do regime de chuvas e das atividades humanas desenvolvidas. De maneira geral, existe maior erosão e transporte de sedimentos no alto da bacia; ocorrendo o seu decréscimo com a diminuição das declividades e da intensidade das chuvas, ou seja, na medida em que há o distanciamento das regiões mais montanhosas. Assim sendo, a degradação do solo predomina na alta bacia, enquanto que a agradação prevalece na parte baixa (CARVALHO, 2008).

2.1.2 Transporte e deposição dos sedimentos

A água é um agente transportador de substâncias, sejam elas dissolvidas ou arrastadas. Portanto, sempre que houver deslocamento de água, natural ou forçada, haverá também a transferência de substâncias e sedimentos. Comumente, a partícula solta é deslocada de sua posição inicial e transportada (diretamente), pelas enxurradas, para os cursos de água; podendo ainda ficar retida em depressões e planícies (CARVALHO, 2008).

Na realidade, os sedimentos presentes nos cursos d'água são originários tanto da erosão na bacia, quanto da erosão no próprio leito e margens do canal, sendo a concentração de sedimentos conduzidos mais intensa na época chuvosa, sobretudo, durante eventos de elevada vazão (CARVALHO, 2008; WMO, 2003, PERRY e TAYLOR, 2007; WHITE e APITZ, 2008). Cerca de 70 a 90% dos sedimentos transportados pelos rios ocorre no período de chuva, principalmente, durante as fortes precipitações (CARVALHO, 2008).

Nessas ocasiões de chuvas, as enxurradas carregam um elevado número de partículas para o rio, que serão movimentadas em suspensão ou então, no leito do canal; rolando, deslizando ou em saltos (CARVALHO et al., 2000). Quando as forças que agem para o deslocamento dessa partícula se reduzem até a condição de ausência de movimento, ocorre o fenômeno de deposição.

O sedimento transportado é também conhecido por carga sólida e quando se considera os padrões de seu movimento, através do canal, pode-se classificá-lo em: i) carga de fundo (ou carga do leito) e, ii) carga em suspensão (ou carga sólida em suspensão). A soma da carga de fundo e da carga em suspensão representa o total de sedimentos que pode ser transportado no canal por um determinado escoamento e sob dadas condições de contorno. Os sedimentos podem ser classificados, ainda, conforme o tamanho da partícula, sua origem e efeitos sobre o processo fluvial. Nesse caso tem-se: i) carga de material do leito (ou carga sólida do material do leito) e, ii) carga de material lavado da superfície (WMO, 2003).

A carga sólida de material do leito corresponde à soma da carga de arrasto do material erodido do leito com uma pequena parcela da carga em suspensão, cuja composição também é de material do leito; uma vez que, o sedimento grosso do leito incorporado à carga fina em suspensão é considerado carga de material do leito (CARVALHO et al., 2000). Já a carga de material lavado da superfície é composta, em sua maioria, por partículas finas, geralmente, com diâmetro inferior a 0,062 mm; sendo que a quantidade carregada até as calhas fluviais depende, basicamente, das fontes de contribuição da bacia (WMO, 2003).

A carga de fundo é usualmente transportada na região próxima ao fundo do canal, deslocando-se por arraste, saltos ou ainda, por deslizamento. Em geral, é formada por material de característica mais grosseira (pedregulhos e areia), tipicamente, com diâmetro da partícula maior do que 2 mm; advindos, em sua maioria, da erosão no próprio canal. Essas partículas são mais densas do que aquelas que se encontram em suspensão, possuindo características hidrodinâmicas e físico-químicas diferenciadas (OWENS, 2008); movendo-se apenas ocasionalmente e permanecendo em repouso na maior parte do tempo (EDWARDS e GLYSSON, 1999). A quantidade de material grosso transportado pelo escoamento está relacionada à capacidade de transporte do sedimento pela corrente, dependendo, deste modo, da composição do leito, dos parâmetros hidráulicos e, especialmente, da vazão líquida (WMO, 2003).

A carga sólida de arraste, segundo o *Subcommittee on Sedimentation*, representa as partículas de sedimentos que rolam ou escorregam longitudinalmente no curso d'água, mantendo contato constante com o leito do rio. Enquanto que a carga sólida saltante seria composta por aquelas partículas que pulam ao longo do curso d'água, sob efeito da correnteza ou pelo impacto com outras partículas (CARVALHO, 2008; WMO, 2003).

A carga sólida em suspensão, por sua vez, compreende as partículas que se mantêm em suspensão na coluna de água, em função das componentes verticais da velocidade do fluxo turbulento, ao mesmo tempo em que estão sendo transportadas pelas componentes horizontais dessas velocidades (CARVALHO, 2008). Habitualmente, essas partículas são compostas de material fino (silte e argila), com diâmetro menor do que 2 mm (OWENS, 2008) sendo, portanto, pequenas o suficiente para permanecerem em suspensão, subindo e descendo na corrente acima do leito do canal (CARVALHO, 2008). Com isso, o movimento dessas partículas é considerado igual à velocidade da corrente, pois a velocidade de sedimentação é, frequentemente, muito baixa (CARVALHO et al., 2000; HUDSON-EDWARDS, 2007). A concentração de material fino transportado depende, basicamente, do suprimento de sedimentos provenientes da bacia, não nutrimdo relação direta com a vazão (WMO, 2003).

Na verdade, a diferenciação da carga transportada em carga suspensa ou carga de fundo depende da relação existente entre as condições de escoamento, o processo de transporte e a estrutura, a densidade e o tamanho da partícula transportada. Nos rios, em geral, o sedimento fino é transportado na forma suspensa (TAYLOR et al, 2008). Contudo, dependendo da velocidade da corrente e do efeito de turbulência, as partículas que se deslocam pelo fundo do canal podem "entrar" ou "saltar" para o meio líquido, passando a se movimentar em suspensão;

permanecendo nesse movimento até que as forças atuantes se reduzam, quando então, voltam a se deslocar (deslizando ou rolando) através do fundo do canal. Esse movimento das partículas no fundo do canal também ocorre em função da ação da corrente, mas a sua velocidade de ocorrência é inferior àquela das partículas em suspensão, em razão da resistência de atrito presente nesse deslocamento (CARVALHO et al., 2000).

Considerando uma granulometria variada, a concentração de sedimentos em um rio apresenta um mínimo na superfície e um máximo perto do fundo do canal, aumentando das margens para o centro da seção transversal. As argilas exibem uma distribuição uniforme ao longo da profundidade. Os sedimentos produzidos nas cabeceiras são compostos por partículas maiores (pedras, pedregulhos e seixos) e, à medida que são transportados em direção à jusante (baixo curso), vão se fragmentando e formando partículas menores (areia grossa, média e fina). Parte dessas partículas menores deposita-se nas margens na forma de lama. Assim, o sedimento encontrado no exutório de rio extensos é predominantemente do tipo muito fino, caracterizando-se basicamente por silte e argila (CARVALHO, 2008).

2.1.3 Caracterização dos sedimentos em bacias rurais

Nas bacias rurais, os sedimentos têm suas características diretamente relacionadas ao uso do solo e às práticas de manejo desenvolvidas, dependendo ainda, do tipo de solo e da cobertura vegetal e de outros fatores de cunho geomorfológico e topográfico. A ação conjunta desses elementos irá afetar, em maior ou menor proporção, a ocorrência dos processos erosivos; determinando a quantidade de material produzido (SALOMONS e BRILIS, 2004).

A magnitude da erosão é influenciada, sobretudo, pelo tamanho da área cultivada, pelas mudanças de uso do solo, pela rotação de culturas e pelas práticas agrícolas aplicadas (UNESCO, 2011); sendo mais significativa durante períodos de revolução da terra (no caso do plantio convencional) ou naquelas épocas em que a cobertura vegetal é menos eficiente (fase logo após plantio, fase inicial de crescimento da planta ou ainda, no período pós-colheita).

Em função do uso do solo pode existir uma acentuada variação na quantidade de sedimentos produzidos entre diferentes bacias, mesmo quando as condições litológicas e climáticas são muito semelhantes (TAYLOR et al., 2008). Portanto, a quantidade de sedimentos e o tamanho das partículas dependem das características da vegetação presente e da área por ela coberta. Assim sendo, uma bacia agrícola com grande parcela de sua área coberta por vegetação terá maior (ou menor) produção de sedimentos finos, em função do tipo de vegetação presente.

Por outro lado, quando existe apenas uma pequena porção da área com cobertura vegetal, a produção de sedimentos será maior e caracterizada por material mais grosso (CARVALHO, 2008).

Os sedimentos de bacias rurais são originados, basicamente, da erosão e da degradação do solo e pela erosão no leito do canal, somados a restos de vegetais e resíduos da pecuária (material orgânico) (SALOMONS e BRILIS, 2004). As principais fontes desses sedimentos são as lavouras, as pastagens (campos) e as estradas, pela sua frequente exposição à erosão por ação da água, máquinas e pastoreio de animais. Ao que cabe destacar que as estradas representam caminhos que facilitam a transferência de sedimentos das fontes para a calha fluvial. Acrescente-se ainda, entre as fontes de sedimentos, a erosão no próprio canal, que tem fundamental importância, já que o material erodido se encontra dentro do curso d'água, o que determina um impacto imediato dessas partículas. Obviamente, essa contribuição do canal dependerá de uma série de fatores, entre os quais: o clima (precipitação e temperatura), as características do fluxo (pico de descarga e duração), as propriedades do material (por exemplo: o tamanho de partícula e o teor de matéria orgânica) e o uso da terra (TAYLOR et al., 2008). Esses fatores definirão a ocorrência em maior ou menor grau (ou a não ocorrência) do processo erosivo em um dado canal.

2.2 Monitoramento da concentração de sedimentos

A maior parte dos sedimentos erodidos na área de drenagem de uma bacia é carreada pelas enxurradas e alcança a calha dos rios. Em virtude disso, a verificação da produção de sedimentos é, na maioria das vezes, realizada na seção transversal dos cursos d'água (CARVALHO, 2008).

A determinação da descarga sólida pode ser realizada por diferentes métodos, diretos (ou *in situ*) e indiretos; sendo essa classificação efetuada em função do tipo de equipamento de medida utilizado e dos demais procedimentos realizados. No Brasil, segundo Carvalho et al. (2000), a sedimentometria tem sido realizada por amostragem de sedimento, seguida de análises no laboratório e cálculos de obtenção da descarga sólida; procedimento incluído entre os métodos indiretos de medida.

O monitoramento da descarga em suspensão é efetuado para o conhecimento da quantidade de sedimento transportado em suspensão, da concentração de sedimentos e, por vezes, para a determinação da distribuição granulométrica das partículas transportadas. Esta é

a fase predominante das medições na medida em que se constitui na maior parcela da carga sólida transportada nos canais, mesmo na situação em que se considera apenas a descarga de material fino (CARVALHO, 2008). Em razão disso, é muito comum, em rios brasileiros, a realização da medição apenas da carga suspensa, com utilização de instrumentos como DH-48, e DH-59. As grandezas fundamentais para a determinação da descarga em suspensão são a concentração de sedimentos e a descarga líquida (CARVALHO, 2008).

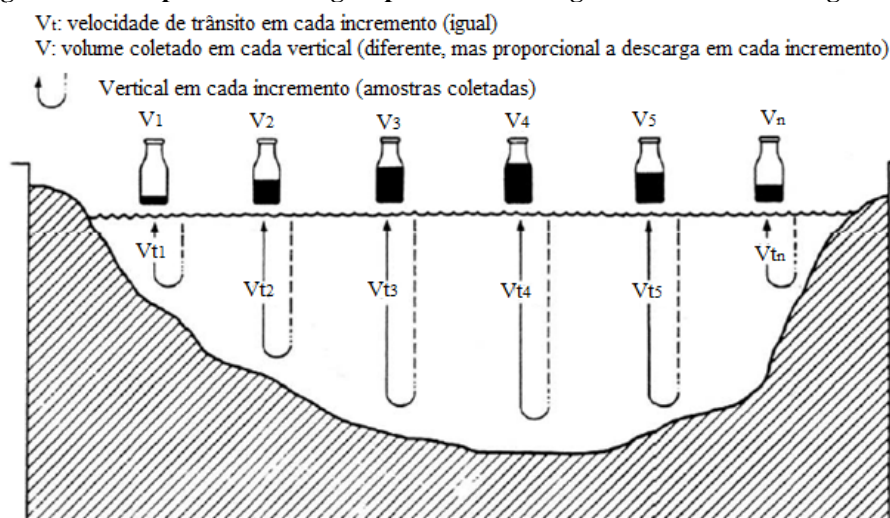
Usualmente, a determinação da CSS é realizada através de coletas de amostras no rio, por meio de amostragem por integração na vertical. Nesse método, o amostrador é abaixado até o fundo do rio em uma velocidade constante (conhecida como velocidade de trânsito ou de percurso) e levado de volta à superfície, também em uma velocidade constante, não necessariamente igual a da descida, mas muito próxima a essa. O tempo de amostragem é, em geral, superior a 10 segundos e a observância da velocidade de trânsito assegura a coleta isocinética e a representatividade das amostras, garantindo que o instrumento desça em uma posição adequada e que o bico receba a amostra na posição horizontal (CARVALHO, 2008). O método permite a obtenção da concentração média na vertical, se a amostra é analisada individualmente, ou a concentração média em toda a seção, para os casos em que são analisadas, conjuntamente, as amostras de todas as verticais em que a seção foi subdividida (EDWARDS e GLYSSON, 1999).

Em geral, a divisão das verticais é realizada pelo método de amostragem por igual incremento de largura (IIL) ou pelo método de amostragem por igual incremento de descarga (IID); ambos possibilitam a simplificação dos trabalhos em laboratório e dos cálculos posteriores (EDWARDS e GLYSSON, 1999; CARVALHO et al., 2000; CARVALHO, 2008; WMO, 2008).

No IIL (Figura 1), a seção do rio é dividida em uma série de segmentos com igual largura, para obtenção de uma série de sub-amostras, sendo que o bico utilizado no amostrador e a velocidade de trânsito são iguais para todas as verticais; o que leva a coleta de amostras com volumes diferentes em cada uma das verticais. Antes da amostragem a seção é dividida em “n+1” seguimentos para obter “n” verticais (CARVALHO, 2008).

A amostragem de sedimentos em suspensão deve ser realizada em um mínimo de 10 e máximo de 20 verticais (CARVALHO et al., 2000) ou entre 6 e 10 verticais (WMO, 2008). As zonas de baixíssimas ou nenhuma velocidade não são consideradas na amostragem (CARVALHO, 2008). Maiores detalhes da metodologia podem ser verificados em Carvalho (2008).

Figura 1 - Exemplo de amostragem pelo método de igual incremento de largura (III)



Fonte: Adaptado de Edwards e Glysson (1999)

A frequência de amostragem dependerá das características de escoamento da bacia. De maneira geral, o sedimento em suspensão deve ser verificado com uma frequência maior durante os períodos chuvosos (CARVALHO et al., 2000). As amostras coletadas são, normalmente, processadas e analisadas em laboratórios especiais para determinação da CSS. A evaporação é o método mais empregado para determinação das baixas concentrações, enquanto que a filtragem é frequentemente utilizada para amostras de média ou elevada concentração (WMO, 2008).

No entanto, é importante considerar que o fluxo em suspensão nos rios dependerá também da disponibilidade de material na bacia e, portanto, dos processos de desagregação do solo e da transferência dos sedimentos da bacia vertente para a calha fluvial; os quais serão influenciados por fatores relacionados à distribuição anual de chuvas, ao uso e ao manejo do solo, às condições geomorfológicas do terreno, à umidade antecedente, etc. (POLETO e MERTEN, 2006). Além disso, nas bacias onde existe distribuição irregular das chuvas e grande variabilidade no tipo de solo e condições geológicas, a concentração de sedimentos no curso d'água será influenciada não somente pelas ocorrências de enchentes no ano, mas também, pelas fontes de escoamento na bacia (CARVALHO et al., 2000).

Há que se destacar que esse tipo de coleta de amostras de sedimentos e posterior análise laboratorial, além de ser onerosa e muitas vezes perigosa— por ser a maior parte dos sedimentos transportados durante eventos de cheia—, também dificulta o desenvolvimento de estudos de modelagem hidrossedimentológica; já que não há a disponibilidade de séries contínuas da concentração de sedimentos, fundamentais à calibração e à verificação dos modelos hidrossedimentológicos. Em razão disso, o emprego de tecnologias substitutas de

monitoramento contínuo desponta, atualmente, como uma alternativa interessante à superação dessas limitações, revelando novos horizontes para o campo da modelagem hidrossedimentológica. Em geral, essas tecnologias possibilitam a determinação indireta da concentração de sedimentos, através de relações com propriedades físicas da água, entre as quais a turbidez.

2.3 A turbidez como medida substituta da concentração de sedimentos suspensos (CSS)³

Usualmente, a determinação da CSS é realizada através da coleta de amostras físicas e de posteriores análises laboratoriais; um processo oneroso e que consome grande quantidade de tempo, recursos humanos e financeiros. Em função disso, o meio científico tem procurado desenvolver métodos alternativos que relacionam a CSS a outras variáveis, buscando a determinação indireta do transporte de sedimentos ao longo do tempo (BAYRAM, KANKAL e ÖNSOY, 2012; BAYRAM et al., 2014). Entre os métodos mais utilizados estão as relações vazão-CSS (GAO e JOSEFSON, 2012; SU, LU e HONG, 2013; TÓTH e BÓDIS, 2015) e as tecnologias alternativas de monitoramento, como os sensores ópticos (HARRINGTON e HARRINGTON 2013; SHELLNBARGER, WRIGHT e SCHOELLHAMER, 2013; HAIMAN et al., 2014; TANANAIEV e DEBOLSKIY, 2014).

Todavia, a aplicação da abordagem clássica da hidromecânica, através de relações vazão-CSS (relações lineares, linearizáveis e não linearizáveis simplificadas), muitas vezes não é suficiente para a adequada modelagem dos processos sedimentológicos; isso porque as características do transporte de sedimentos nos rios compõem-se pela interação de processos complexos e não-lineares (BOUKHRISSA et al., 2013; AFAN et al., 2015). Com efeito, o uso da curva-chave de sedimentos assume, por exemplo, que a vazão é um bom parâmetro preditor da CSS, o que nem sempre é verdadeiro. Além disso, também é assumido que o pico da CSS coincide com o pico da vazão (FINLAYSON, 1985). Os erros envolvendo essa curva-chave dependem de vários fatores, tais como: a natureza das bacias, o intervalo de tempo em que a carga será calculada, o procedimento utilizado na obtenção da curva e a aplicação da curva de calibração (WALLING, 1977).

³ Escrito com base em:

SARI, V.; CASTRO, N.M. dos R.; KOBAYAMA, M. Estimativa da concentração de sedimentos suspensos com sensores ópticos: revisão. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 4, p. 816-836, 2015.

Em contrapartida, avanços ocorridos nas últimas décadas, em termos de tecnologias substitutas para monitoramento do transporte de sedimentos suspensos em rios, têm mostrado que essas tecnologias representam uma alternativa promissora para a substituição dos métodos tradicionais de coleta de sedimentos e para a implantação de sistemas de monitoramento mais eficientes. Em março de 2009, o Serviço Geológico dos Estados Unidos (USGS) aprovou a utilização dos sensores ópticos (turbidímetros) em programas de monitoramento de sedimentos suspensos, sendo essa a primeira tecnologia substituta a receber semelhante autorização (ANDERSON et al., 2010).

De fato, diversos estudos têm demonstrado a estreita relação existente entre a turbidez e a CSS (HAIMAN et al., 2014; HARRINGTON e HARRINGTON, 2013; MARTTILA e KLOVE, 2012; NAVRATIL et al., 2011; SHELLNBARGER, WRIGHT e SCHOELLHAMER, 2013; TANANAEV e DEBOLSKIY, 2014; TENA et al., 2011; VOUSDOUKAS et al., 2011), possibilitando o uso dessa variável como medida indireta da CSS. No entanto, a transformação das leituras de turbidez em valores de CSS não é simples e, por isso, apesar dessa tecnologia substituta ser considerada uma técnica madura, bem difundida e relativamente bem documentada (GRAY e GARTNER, 2009; KUHNLE e WREN, 2003), a incerteza associada ao uso dessa variável é ainda elevada (HUDSON, 2001; PRUIT, 2002).

Na realidade, os resultados obtidos dessa conversão são dependentes de: a) os instrumentos utilizados; b) a calibração dos instrumentos; c) a manipulação das amostras utilizadas na calibração e; d) como, quando e onde as amostras foram coletadas (HUDSON, 2001; PRUIT, 2002). Portanto, a construção de uma relação precisa entre o sinal registrado por um sensor óptico e a CSS está fortemente ligada a uma adequada calibração entre a resposta do sensor e a CSS; sendo essa resposta influenciada por fatores oriundos do sedimento, referentes ao instrumento de monitoramento e, relacionados à qualidade da água e ao fluxo no canal.

Por isso, antes de implantar uma tecnologia alternativa para determinação da CSS, é indicado estudar e caracterizar a dinâmica dos sedimentos na bacia em questão, procurando-se identificar e distinguir as propriedades que mais interferem na relação CSS-turbidez durante o processo de calibração de um dado instrumento.

2.3.1 Teoria da óptica

Os sensores ópticos baseiam-se na teoria de que um raio incidente em uma mistura está sujeito a processos de absorção, dispersão e transmissão, em razão da presença de partículas

suspensas no meio líquido (BISANTINO, GENTILE e LIUZZI, 2011). Dessa maneira, a CSS é determinada, indiretamente, por meio de sua relação com características físicas específicas; em geral, pela detecção da radiação dispersa, refletida ou absorvida pela matéria em suspensão.

Essa propriedade óptica do líquido, através da qual os raios de luz são dispersos no meio líquido e absorvidos (pelas partículas sólidas e/ou dissolvidas), ao invés de serem transmitidos em linha reta através da amostra, é conhecida como turbidez. Sua causa relaciona-se à presença de materiais orgânicos e minerais em suspensão e/ou dissolvidos nesse meio, tais como: argila, silte, matéria orgânica, plâncton e outros organismos microscópicos, ácidos orgânicos e corantes (ASTM INTERNATIONAL, 2003; LEWIS, 2002).

2.3.2 Fatores que influenciam o sinal identificado por um sensor óptico

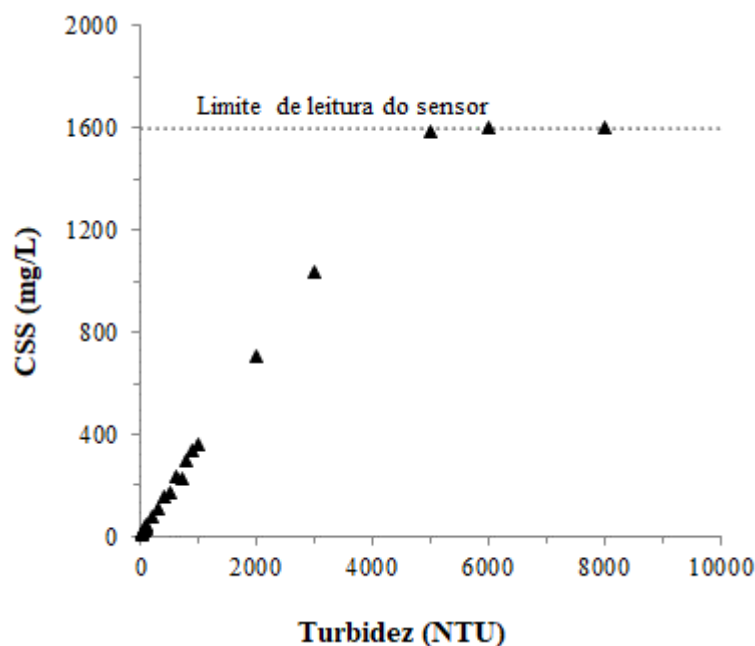
O sinal identificado por um sensor óptico é afetado por fatores como: a CSS, o tamanho, a forma, a cor, o índice de refração, a densidade e a composição mineralógica da partícula de sedimento transportado, as características do comprimento de onda da luz incidente, a presença de incrustações e de arranhões na superfície óptica do sensor, a presença de determinados componentes na coluna de água e algumas propriedades do escoamento. As próximas seções apresentam uma descrição mais detalhada acerca da influência desses fatores.

2.3.2.1 Concentração de sedimentos suspensos (CSS)

Variações na CSS compõem o principal fator de influência sobre o sinal registrado por um sensor óptico, podendo ocasionar alterações na ordem de 1000 vezes sobre a saída do sensor (DOWNING, 2006).

Inúmeros estudos têm reportado a existência de uma relação crescente entre a turbidez e a CSS (ABE et al., 2012; HAIMANN et al., 2014; HARRINGTON e HARRINGTON, 2013; NAVRATIL et al., 2011; SHELLNBARGER, WRIGHT e SCHOELLHAMER, 2013; TENA et al., 2011; VOUSDOKAS et al., 2011), apresentando uma resposta mais elevada do sensor na medida em que a CSS aumenta (Figura 2). Isso ocorre porque a presença de partículas suspensas no meio líquido provoca a dispersão da energia emitida pelo sensor, afetando a leitura que ele faz da energia refletida. Por consequência, quanto maior for a quantidade dessas partículas na coluna de água, maior será a energia dispersada por elas (SADAR, 1998).

Figura 2 - Variação da turbidez em função da concentração de sedimentos suspensos (CSS) para um sensor DTS-12. Calibração realizada em laboratório utilizando amostras de sedimento suspenso coletadas *in situ*



Fonte: Sari, Castro e Kobiyama (2015)

Comumente, a relação reportada entre a turbidez e a CSS é do tipo linear, embora também sejam descritas relações do tipo potência ou polinômio de segunda ordem e, em alguns casos, polinômios de terceira ordem. Também têm sido empregadas transformações nos dados de entrada, usualmente na forma logarítmica (Tabela 1). Há que se considerar, entretanto, que essa relação entre a resposta do sensor e a CSS é individual para cada local monitorado e tipo de instrumento utilizado; muitas vezes, variando conforme as características do fluxo atuante e as estações hidrológicas.

Altas concentrações de sedimentos podem afetar negativamente a resposta do sensor, em razão do bloqueio parcial do feixe emitido, do espalhamento múltiplo (KINEKE e STERNBERG, 1992), ou ainda, devido à saturação do sinal (LUDWIG e HANES, 1990).

De fato, os sensores apresentam um limite máximo de leitura, conforme características do instrumento, principalmente, em função do comprimento de onda da energia incidente (Figura 2). Esse limite define a CSS máxima que ele conseguirá identificar, dependendo igualmente de características do sedimento; entre as quais, o diâmetro da partícula transportada. Logo, propriedades inerentes à partícula também influenciam nos processos de dispersão e na absorção da energia e, portanto, na resposta identificada pelo sensor.

Tabela 1 - Descrição de estudos internacionais que utilizaram sensores ópticos como medida indireta da CSS Continua

Autor	Local	Sensor (resolução/ λ)	Período calibração	Tipo de ajuste	Função	NS/R ² /R
Finlayson (1985)	bacia de Myrtle Creek nº 1 (Victória, Austrália)	Partech Model LP-740-3R	132 amostras	polinômio 2º ordem	CSS = $-24,17 + 3,71x + 0,02x^2$ (x: % completa de reflexão do sensor)	R ² =0,97
Brasington e Richards (2000)	sub-bacias da bacia de Likhu Khola, norte de Kathmandu (Nepal Middle Hills)	bacias de Bore, Dee e Jogi : Partech IR04C infrared sensor (0-10 g/L) bacia de Chinniya: Partech IR39C sensor (0-1,5 g/L)	5 meses (maio a setembro/92)	linear (campo) cúbica (laboratório)	-	R ² =0,75 (campo)
Hudson (2001)	bacia de Russell Creek (Vancouver Island, Canadá)	optical backscatter sensor: OBS-3 (calibrado para 0-500 NTU/865 nm)	8 anos (1991-1998)	não-linear (polinômio 2º ordem)	SF: CSS= $-0,1.T+0,14.T^2$ SN (T>40 NTU): CSS= $1,68.T+0,0358.T^2$ SN (T>40 NTU): CSS= $-1,06+2,46.T+0,0109.T^2$ SG: CSS= $3,49.T+0,0129.T^2$	R ² =0,743 R ² =0,984 R ² =0,993 R ² =0,996
Gray et al. (2003)	Rio Kansas (DeSoto, Kansas, EUA)	sensor de turbidez nefelométrico (0-1000 NTU)	4 anos (1999 a 2002)	linear	SSC = $1,797.T^{0,905}$	R ² =0,93
Macdonald et al. (2003)	3 tributários de Baptiste Creek (Fort St. James Forest District, British Columbia)	optical backscatter sensor OBS	7 anos (1996, 1997-2001)	linear	TSS = $0,44(OBS) + 1,25$ (TSS em ppm e OBS em mV)	R ² =0,64
Old et al. (2003)	4 locais na bacia de Bradford Beck (West Yorkshire, Inglaterra)	sensor de turbidez Analite modelo 195/4/30 (0-1000 NTU)	Middlebrook - 6 meses (janeiro-junho/01) Transco, Stanley Cars e Shipley Weir - 2 meses (maio-junho/01)	linear (Middlebrook) e polinômio de 2º ordem (Transco, Stanley Cars e Shipley Weir)	Middlebrook: CSS= $1,1603.T$ Transco: CSS= $0,0005T^2+0,9676.T$ Stanley: CSS= $0,0011.T^2+0,9013.T$ Shipley Weir: CSS= $0,0013.T^2+0,6852.T$ (T em FTU)	R ² =0,82 R ² =0,87 R ² =0,78 R ² =0,97
Pfannkuche e Schmid (2003)	Rio Elbe (Alemanha)	nephelometer TMS 200, Smt & Hybrid (não especificado)	4 anos e 8 meses (junho/96 a fevereiro/01)	-	CSS= $0,695.T+15,20$ (*todos os dados) Q \leq 600 m ³ /s: CSS= $0,0103.Q^{0,7384}.T+15,20$ Q > 600m ³ /s: CSS= $\left[\frac{0,97}{1+7,822e^{-0,011Q}} \right] T + 15,20$ (CSS em g/m ³)	R ² <0,6 R ² =0,972 R ² =0,998
Schoellhamer e Wright (2003)	rio Sacramento (Freeport, Califórnia) e rio Colorado (Utah, EUA)	Optical backscatterance sensor (OBS)	rio Sacramento: 3 anos (entre 1998 e 2001) rio Colorado: 3 dias (10 a 12 maior/95)	rio sacramento: linear rio Colorado: não estabelecida relação (ajuste ruim)	rio Sacramento: CSS= $1,03.X+2$ (X- resposta do sensor em mV)	
Uhrich e Bragg (2003)	3 tributários (North Santiam, Breitenbush e Blowout) na bacia do rio North Santiam (Oregon, EUA)	YSI multiparameter sonde (não especificado)	2 anos (1999 e 2000)	potencial	North Santiam: CSS = $1,70.T^{1,04}.$ (1,10) Breitenbush: CSS = $1,85.T^{0,988}.$ (1,17) Blowout: CSS = $1,45.T^{1,08}.$ (1,13)	R ² =0,912 R ² =0,948 R ² =0,964
Lietz e Debiak (2005)	bacia de Lake Worth Lagoon (Palm Beach County, Flórida)	YSI 600 - 6136 turbidity sensor (0-1000 NTU/ 860 nm)	12 meses (outubro/03 a setembro/04)	-	Log ₁₀ CSS = $0,30 + 0,75.Log_{10}T$ Log ₁₀ CSS = $0,19 + 0,78.Log_{10}T$ Log ₁₀ CSS = $0,38 + 0,56.Log_{10}T + 0,0001Q$ (T em FNU)	R ² =0,85 R ² =0,90 R ² =0,90
Rasmussen, Ziegler e Rasmussen (2005)	parte baixa do rio Kansas (Kansas, EUA). Tres estações analisadas: Wamego, Topeka e DeSoto	sensor de turbidez YSI - modelo 6026 (0-1000 NTU/ 860 nm)	3 anos e 11 meses (janeiro/00 a dezembro/03)	-	Wamego: logCSS = $0,91.logT-0,271$ Topeka: logCSS = $1,09.logT-0,0537$ DeSoto: logCSS = $0,904.logT+0,264$ 3 estações: logCSS = $0,969.logT+0,161$ (T em FNU)	R ² =0,95 R ² =0,98 R ² =0,88 R ² =0,93
Estrany, Garcia e Battala (2009)	bacia de Can Revull (Ilha de Mallorca, Espanha)	McVan Analite NEP-9516-G (0-1600 NTU)	12 meses (outubro/04 a setembro/07)	linear	CSS = $0,93.T + 8,67$	R ² =0,98

Tabela 1 - Descrição de estudos internacionais que utilizaram sensores ópticos como medida indireta da CSS

Fim

Autor	Local	Sensor (resolução/ λ)	Período calibração	Tipo de ajuste	Função	NS/R ² /R
Mano et al. (2009)	bacias de Asse, Bléone, Romanche e Ferrand (Alpes do sudeste da França)	sensor de turbidez (não especificado)	Asse: 2 anos e 6 meses (19/06/01 a 31/12/03) Bléone: 2 anos e 5 meses (05/07/01 a 31/12/03) Ferrand: 2 anos e 6 meses (27/04/02 a 13/10/04) Romanche: 1 ano e 12 meses (03/06/02 a 17/12/03)	linear	Asse: CSS=2,16.T Bléone: CSS=0,99.T Ferrand e Romanche: CSS=1,02.T (CSS em g/L e T em ut)	R ² =0,98
Navratil et al. (2011)	Rio Galabre (La Robine, França)	nephelometric turbidimeter WTW Visolid 700-IQ (0-10.000 NTU)	3 anos (2007–2009)	polinômio 2º ordem	CSS=0,032.T ² +0,262.T (CSS em g/L e T em g/L de S ₂ O ₂)	R ² =0,97
Rasmussen et al. (2011)	Rio Little Arkansas (Sedgwick, Kansas, EUA)	YSI 6026 turbidity sensor (0-1000 NTU/860 ±30µm)	6 anos (1999 a 2005)	potencial	log ₁₀ (CSS) = 0,943 log ₁₀ (T) + 0,130 ou CSS = 1,39.T ^{0,943} (T em FNU)	R ² =0,98
Tena et al. (2011)	Rio Ebro (Iberian Peninsula)	Hach SS6 turbidity probe (0-9999 NTU)	7 anos (2002 a 2008)	linear	CSS=0,83.T - 1,30	R ² =0,9
Abe et al. (2012)	5 sub-bacias dos rios Mu e Saru (Hokkaido, Japão)	ATU3-8M (0-20.000 ppm) ATU75W-USB (0-100.000 ppm)	10 meses (março a dezembro/10)	linear	ATU3-8M: CSS = (0,0027.Q + 0,2482).T ATU75W-USB: CSS=(0,0020Q + 0,2898).T (T em ppm)	R ² = 0,877 R ² = 0,904
Buschman et al. (2012)	rio Berau (Gunung Tabur, Indonésia)	YSI 600 OMS (0-1000 NTU)	2 meses (maio e setembro/07)	linear	CSS = 0,33.T-0,0018 (CSS em kg/m ³ e T em Volts)	R ² = 0,72
Chikita et al. (2012)	rio Yukon (Alasca)	ATU3-8M (0 - 20.000 ppm)	3 anos e 3 meses (junho/06 a setembro/09)	linear	CSS = 0,7656.T + 59,733 (T em ppm)	R ² = 0,756
Marttila e Klove (2012)	3 locais na Finlândia (Virkorinne, Virkosuo e Keuhkosenneva)	YSI 600 OMS (0-1000 NTU)	3 meses (junho a agosto/08)	linear (melhor ajuste)	Virkosuo: CSS =0,62.T -7,52 Virkorinne: CSS=0,59.T- 9,34 Keuhkosenneva: CSS=0,77.T -8,99	R ² =0,94 (Virkorinne e Virkosuo) e 0,74 (Keuhkosenneva)
Harrington e Harrington (2013)	rio Owenabue (Ballea Bridge Upper) e rio Bandon (Curranure)	Optical backscatter turbidity sensor: OBS 3+ (0-4000 NTU/850 µm)	Rio Owenabue: 1 ano (15/09/09 a 15/09/10) Rio Bandon: 1 ano (10/02/10 a 09/02/11)	linear	-	R ² =0,87 (rio Bandon) e 0,97 (rio Owenabue)
Haimann et al. (2014)	rio Danube (Áustria)	sensor óptico (não especificado)	2 anos (2008 e 2009)	linear	2008: CSS = 0,75.T 2009: CSS=0,754.T (T em mg/L)	R ² = 0,93 R ² =0,95
Slaets et al. (2014)	bacia de Chiang Khoi (Vietnã)	sensor de turbidez Analite NEP-395 (0-1000 NTU/860 µm)	7 meses, durante a estação chuvosa (abril a outubro de 2010 e 2011)	linear misto	CSS=f(T) e CSS=f(T, Q) (CSS em g/L)	R=0,86 (CSS=f(T)) e 0,87 (CSS=f(T, Q))
Ziegler et al. (2014)	Rio Sa (Tailândia)	sensor de turbidez Analite NEP-395 (0-1000 NTU/ 860 µm)	3 anos (2006, 2007 e 2008)	potencial	2006: TSS=9,963.T ^{0,06} (T≤200 NTU) e TSS= 99,981.Q ^{1,15} +0,2795.T ^{1,15} (T>200 NTU) 2007: TSS=11,02.T ^{0,56} (T≤200 NTU) e TSS= 347,66.Q ^{0,98} +0,0004.T ^{1,99} (T>200 NTU) 2008: TSS=9,93.T ^{0,5} (T≤200 NTU) e TSS= 99,91.Q ^{1,29} +0,000005.T ^{2,6} (T>200 NTU)	NS=0,9 (2006) e 0,75 (2007 e 2008)

(λ -xxxxx NTU)= faixa estipulada pelos autores desse trabalho, conforme modelo utilizado nos estudos (informações fabricante)
SF= sedimento fino, SN= sedimento normal, SG= sedimento grosso; transportados conforme regime atuante

Quando não especificado: T em NTU e CSS em mg/L
TSS: sólidos suspensos total Q: vazão
T: turbidez CSS: concentração de sedimentos suspensos

Fonte: Sari, Castro e Kobiyama (2015)

2.3.2.2 Tamanho da partícula de sedimento transportado⁴

O tamanho da partícula de sedimento transportado compõe o segundo fator de maior influência sobre a resposta de um sensor óptico, exercendo grande interferência na construção da relação turbidez-CSS. As alterações ocasionadas sobre a saída do sensor podem ser da ordem de 100 vezes (DOWNING, 2006).

De forma geral, pode-se dizer que a variação do sinal do sensor possui característica inversa ao tamanho da partícula (Figura 3), ou seja, quanto menor a partícula transportada maior o valor registrado pelo sensor (CLIFFORD et al., 1995; CONNER e VISSER, 1992; FOSTER, MILLINGTON e GREW, 1992; HUDSON, 2001; KLEIZEN et al., 1995; LUDWING e HANES, 1990; SUTHERLAND et al., 2000; HUDSON, 2001; MERTEN, CAPEL e MINELLA, 2014; SARI, CASTRO e KOBIYAMA, 2015; SARI et al., 2017). Esse comportamento deve-se ao fato de que sedimentos de menor granulometria têm superfícies mais reflexivas por unidade de massa, devido a sua maior área específica, gerando maior poder de reflexão da luz. Por isso, para um dado valor constante de CSS, a resposta do sensor tende a aumentar à medida que o sedimento em suspensão se torna mais fino (SCHOELLHAMER e WRIGHT, 2003; SARI et al., 2017).

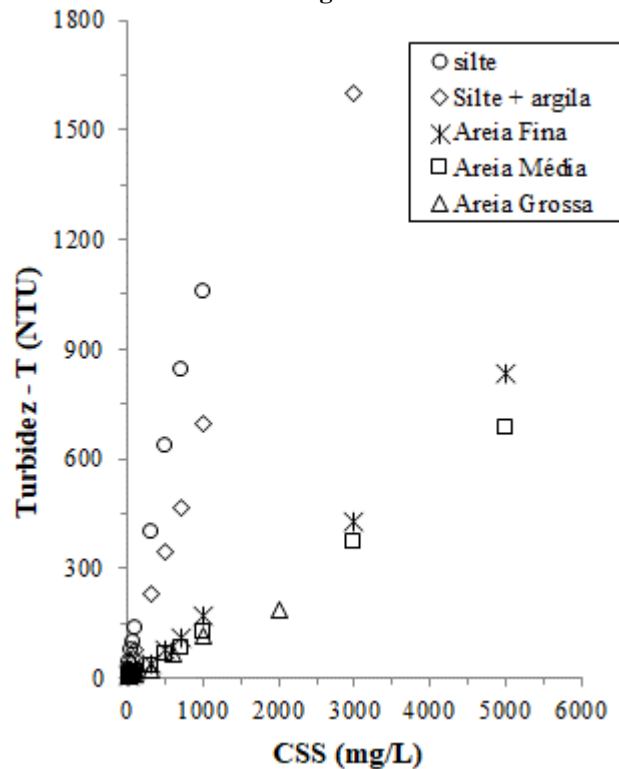
Na realidade, essa interferência depende da proporção entre o tamanho da partícula e o comprimento de onda da energia emitida pelo sensor. Partículas com dimensão $\frac{1}{10}$ de comprimento de onda da energia incidente espalham os raios de forma simétrica, em todas as direções; enquanto que, as partículas maiores, com aproximadamente $\frac{1}{4}$ do comprimento de onda da energia incidente, causam uma dispersão mais concentrada na parte frontal. Já aquelas partículas com dimensão muito superior ao comprimento de onda da energia incidente ocasionam uma concentração extrema do espalhamento na região frontal, desenvolvendo máximas e mínimas intensidades de espalhamento em ângulos maiores (BISANTINO, GENTILE e LIUZZI, 2011; SADAR, 1998). Isso leva a uma maior sensibilidade do instrumento para partículas mais finas em comparação àquelas de maior diâmetro (LEWIS, 1996).

⁴Escrito com base em:

SARI, V.; PEREIRA, M.A.F.; CASTRO, N.M. dos R.; KOBIYAMA, M. Efeitos do tamanho da partícula e da concentração de sedimentos suspensos sobre a turbidez. **Revista de Engenharia Sanitária e Ambiental**, v. 22, n. 2, p. 213-219, 2017.

SARI, V.; CASTRO, N.M. dos R.; KOBIYAMA, M. Estimativa da concentração de sedimentos suspensos com sensores ópticos: revisão. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 4, p. 816-836, 2015.

Figura 3 - Relação entre a concentração de sedimentos suspensos (CSS) e a turbidez (T), considerando diferentes faixas granulométricas



Fonte: Sari, Castro e Kobiyama (2015)

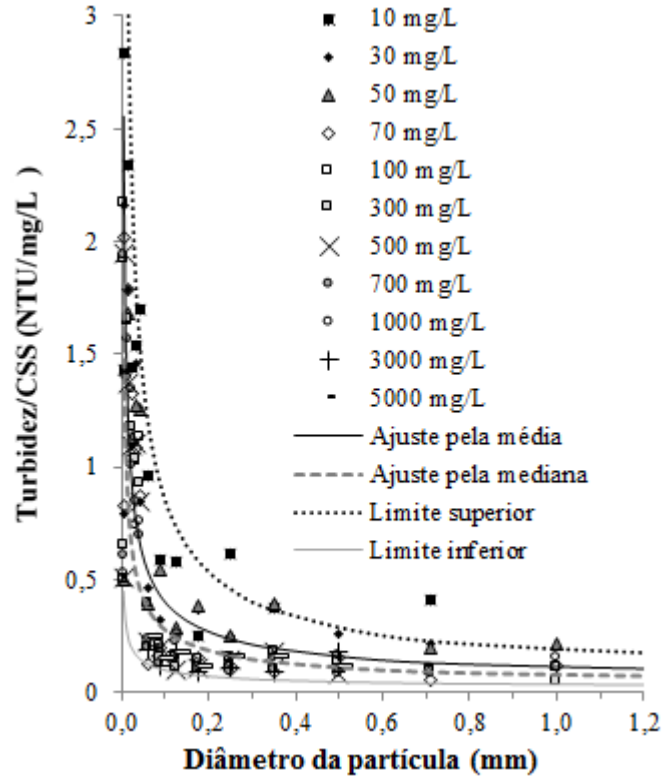
A maior ou a menor variação da turbidez (sensibilidade do sensor), expressa pela razão entre a turbidez e a CSS (Figura 4) também é influenciada pelo diâmetro do sedimento, sendo que as partículas pequenas tendem a gerar maiores alterações da turbidez para elevações da CSS. Na medida em que o diâmetro da partícula aumenta, essa variação decai, até que se alcance uma condição de variação quase constante para diâmetros superiores a 0,2 mm. A variação da sensibilidade de um sensor, em relação às alterações no diâmetro da partícula transportada, pode ser expressa na forma de uma função do tipo potência.

Dessa forma, quanto maior for a sensibilidade do sensor a uma dada classe granulométrica, mais sensível esse sensor será para ocorrências de variações na CSS; ou seja, as alterações da CSS para partículas de sedimento de menor diâmetro resultarão em variações de turbidez mais facilmente identificáveis pelo sensor em comparação com aquelas ocasionadas por partículas maiores. Por consequência, o erro introduzido pela utilização de um sensor óptico dependerá da variabilidade temporal e espacial das propriedades da partícula de sedimento e da CSS transportada em um dado evento.

De fato, conforme a distribuição granulométrica dos sedimentos transportados, podem ocorrer respostas semelhantes das leituras de turbidez para diferentes CSS, ou ainda, respostas diferentes de turbidez para iguais CSS. Para melhor avaliar esta questão são apresentadas na

Tabela 2 as diferentes respostas do sensor ao sinal de turbidez para as mesmas concentrações de sedimentos, considerando a análise de diferentes faixas granulométricas (areia grossa, areia média, areia fina, silte e silte + Argila).

Figura 4 - Relação Turbidez/CSS para diferentes diâmetros da partícula de sedimento



Fonte: Sari, Castro e Kobiyama (2015)

Tabela 2 - Turbidez em função da concentração de sedimentos suspensos, para as classes granulométricas areia grossa, areia média, areia fina, silte e mistura silte+argila.

CSS (mg/L)	Turbidez (NTU)				
	Areia Grossa	Areia Média	Areia Fina	Silte	Silte + Argila (<0,063 mm)
10	5,16	4,94	5,93	19,69	14,84
30	7,95	7,56	10,42	44,00	22,39
50	12,31	12,66	19,94	76,51	40,26
70	13,16	8,04	12,88	99,34	54,50
100	19,62	15,30	22,66	139,75	75,95
300	22,57	33,19	40,88	402,51	229,71
500	-	67,52	78,64	635,71	348,03
700	-	81,37	112,32	845,96	464,02
1000	114,59	124,06	171,27	1058,25	696,79
3000	-	370,92	430,13	-	1600,95
5000	-	686,12	831,10	-	-

Fonte: Sari et al. (2017)

Pode-se analisar, por exemplo, que para pequenos valores de CSS (em torno de 10 até 100 mg/L) não existem grandes diferenças nas leituras de turbidez do sensor para as classes granulométricas das areias grossa, média e fina; ou seja, para uma mesma CSS têm-se respostas semelhantes de turbidez. No entanto, à medida que a CSS aumenta, essas diferenças de leitura do sensor tendem a tornarem-se mais evidentes ($CSS > 300$ mg/L). Por outro lado, para sedimentos mais finos (silte e mistura silte+argila), as leituras de turbidez diferem bastante daquelas observadas para a classe das areias, das menores às maiores CSS ensaiadas. Para $CSS = 10$ mg/L de silte ou de silte+argila, por exemplo, têm-se uma resposta de turbidez equivalente a uma CSS em torno de 100 mg/L para a classe das areias; enquanto que, para uma $CSS = 300$ mg/L para a classe silte, tem-se uma resposta do sensor equivalente a uma CSS próxima de 3000 mg/L para as areias.

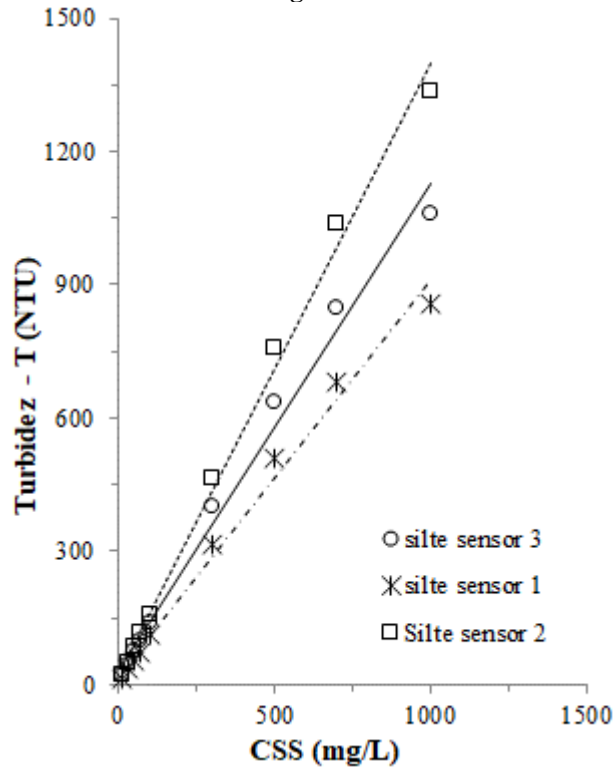
Observa-se, pois, que uma mesma CSS pode resultar em diferentes leituras do sensor de turbidez, conforme a granulometria analisada. Da mesma forma, um mesmo valor de turbidez pode estar relacionado a diferentes CSS quando se compara a resposta do sensor nos extremos das classes de material fino (silte ou silte+argila) e grosso (areias). Em contrapartida, para materiais de mesma classe granulométrica (areia grossa, média e fina) podem-se obter respostas semelhantes de leitura de turbidez para uma mesma CSS (sobretudo para baixos valores de CSS) e respostas um pouco diferenciadas quando a CSS está mais elevada. Há que se considerar, todavia, a possibilidade da influência de variações da forma da partícula de sedimento sobre os resultados de leitura de turbidez registrados nesse experimento.

Desse modo, os resultados demonstram que a resposta do sensor é bastante influenciada pelo tamanho da partícula de sedimento transportada, ainda mais quando se considera a possibilidade da presença dos extremos granulométricos da partícula de sedimento em um mesmo evento. Isso sugere que as variações no percentual de cada granulometria, presente no sedimento transportado em um dado evento (e também, de um evento para outro), podem resultar em respostas bastante diferenciadas dos valores de turbidez registrados pelo sensor; o que, por sua vez, pode se revelar uma dificuldade na construção das curvas de calibração do instrumento.

Acrescente-se ainda, que sensores de mesmo modelo e características geométricas (comprimento de onda da energia incidente e ângulo de detecção) podem responder de forma diferenciada a uma mesma CSS e a um mesmo diâmetro da partícula (Figura 5); evidenciando a importância da construção de curvas de calibração para cada equipamento utilizado nos

monitoramentos, mesmo para aqueles casos em que os instrumentos apresentam as mesmas propriedades ópticas e geométricas.

Figura 5 - Relação turbidez (T) e concentração de sedimentos suspensos (CSS) para três sensores DTS-12, com características geométricas semelhantes



Fonte: Sari, Castro e Kobiyama (2015)

Segundo Lenzi e Marchi (2000), a influência do tamanho da partícula é menos significativa para pequenas bacias, quando comparadas a grandes bacias. Isso porque as primeiras são caracterizadas por regimes pluviométricos e tempos de erosão homogêneos e, portanto, por partículas mais homogêneas. Por outro lado, as segundas apresentam regimes e tipos de solo mais heterogêneos, o que ocasiona maior variação das partículas de sedimento transportadas. Nessas situações, em rios em que a granulometria do sedimento é muito variável, pode-se esperar que a utilidade da turbidez como medida substituta da CSS apresente certas limitações (LEWIS, 2003); havendo, deste modo, a necessidade de uma avaliação minuciosa da possibilidade de se implantar tal tecnologia alternativa como medida indireta da CSS.

A avaliação da resposta dos sensores em função do tamanho das partículas também é extremamente relevante na determinação da turbidez máxima e mínima identificada por um dado instrumento. Em geral, o limite superior estabelecido para sensores nefelométricos— caracterizados pela medida da luz dispersa a 90° em relação à luz incidente, no espectro do visível ou infravermelho (ANDERSON et al., 2010)— está entre 1.000 e 2.000 mg/L

(RASMUSSEN et al., 2011); e para os sensores OBS—sensor que mede a luz dispersa para trás, em um ângulo menor do que 180° , no espectro do infravermelho e em um pequeno volume, na ordem de poucos cm^3 (ANDERSON et al., 2010)— encontra-se entre 4.000 e 50.000 mg/L (RASMUSSEN et al., 2011).

Todavia, é imprescindível apontar que a magnitude dessa variação está relacionada às características ópticas e geométricas de cada instrumento, podendo ser maior ou menor de acordo com o comprimento de onda da energia emitida pelo sensor e, conforme sua relação com as propriedades das partículas consideradas. Logo, esses limites são únicos para cada sensor e devem ser verificados, quantificados e documentados periodicamente (ANDERSON, 2005), considerando as características das partículas transportadas; já que tais limites dependem, em parte, da distribuição e tamanho das partículas (GARTNER e GRAY, 2003). Além disso, em algumas situações, pode ocorrer comprometimento da estabilidade do sensor ao longo do tempo, o que provocaria alterações em sua capacidade de leitura. Os valores mínimos e máximos definirão os limites ideais para os quais o modelo de calibração elaborado poderá ser utilizado (RASMUSSEN et al., 2011).

Com base no exposto, pode-se considerar que a proporção de material de cada classe granulométrica (areia, silte, argila, etc.), presente em um dado evento, influenciará a resposta do sensor. Nesse aspecto, Ludwig e Hanes (1990) observaram que a presença de lama (1 g/L e 2 g/L) em amostras de areia coletadas em Louisiana, ocasionam o aumento da leitura de sensores OBS, sendo a resposta do sensor mais elevada para maiores proporções de lama. Green e Boon (1993) também mostraram que diferentes misturas de silte e areia (nas proporções 80:20, 50:50 e 20:80, sendo silte:areia) geram respostas distintas no sensor OBS-2, para uma mesma CSS.

Portanto, caso a granulometria do sedimento *in situ* varie consideravelmente, temporal ou espacialmente, em relação àquela utilizada na confecção da relação turbidez-CSS, a curva de calibração construída para esse sensor poderá mostrar-se ineficiente; comprometendo a conversão dos valores de turbidez em valores de CSS. Comportamento semelhante foi reportado por Merten, Capel e Minella (2014). Os autores analisaram as leituras de três sensores ópticos (Solar SL 2000-TS, DTS-12 e YSI 6136), considerando cinco proporções de areia e finos (0:100, 25:75, 50:50, 75:25 e 100:0, sendo areia: finos) e uma CSS de 1000 mg/L. Os resultados revelaram que a presença de areia nas misturas reduziu a turbidez registrada pelos sensores, em uma proporção linear.

Por isso, as alterações nas características das partículas de sedimento transportado devem ser sempre verificadas em campo, buscando-se analisar a existência de variações temporais, conforme o regime de vazão atuante nas diferentes estações hidrológicas. Em algumas situações, pode ser indicada a construção de curvas de calibração variáveis em função da vazão atuante. Isso possibilitaria a consideração indireta das alterações das propriedades das partículas, já que a magnitude da vazão define a capacidade de transporte de materiais mais grosseiros pelo escoamento.

Pfannkuche e Schmid (2003), ao analisar a relação entre a turbidez e a CSS no rio Elbe (Alemanha), verificaram que um ajuste mais adequado poderia ser obtido pela introdução da vazão no modelo elaborado, construindo-se duas curvas de calibração distintas, uma para vazões superiores a 600 m³/s e outra para as vazões inferiores. O modelo inicialmente construído utilizava apenas a turbidez como entrada para o cálculo da CSS, empregando todo o período de dados disponíveis ($R^2=0,6$). A separação dos dados entre vazões superiores e inferiores a 600 m³/s, somada a introdução do termo vazão no modelo inicial, possibilitou o desenvolvimento de curvas de ajustes mais adequadas ($R^2=0,972$ e $0,998$, para vazões inferiores e superiores ao limite estabelecido, respectivamente).

2.3.2.3 Forma e rugosidade da partícula de sedimento transportado

A forma da partícula presente no meio líquido e sua rugosidade podem afetar a intensidade de dispersão da energia incidente. Essas propriedades podem alterar a resposta do sensor de 2 a 10 vezes em relação àquela esperada para grãos equivalentes, que possuam características mais suaves. Entretanto, no caso dos grãos naturais, é muito difícil separar os efeitos ópticos da forma e da rugosidade do grão (BUNT, LARCOMBE e JAGO, 1999).

As partículas individuais serão opticamente mais ativas caso apresentem uma elevada relação entre a área da seção transversal e o volume, isto é, quando possuem formato lamelar (BUNT, LARCOMBE e JAGO, 1999). Em geral, as areias possuem dimensões mais uniformes e podem ser representadas por uma esfera, enquanto que as argilas se caracterizam por formatos mais laminares ou alongados (HILLEL, 1982).

Comumente, as partículas esféricas (mais arredondadas) apresentam maior proporção de dispersão da energia na direção de frente para trás, em comparação com aquelas partículas coloidais ou aquelas com forma mais alongada (SADAR, 1998), que distribuem a energia em

todas as direções, possibilitando a identificação de maior quantidade de energia pelo sistema de detecção do sensor.

De fato, Asano e Sato (1980) e Latimer (1984) mostraram que desvios da esfericidade e a existência de projeções radiais podem aumentar o espalhamento da energia. Da mesma forma, Baker e Lavelle (1984), ao descreverem a atenuação causada por sedimentos naturais como sendo maior do que aquela gerada por grânulos de vidro atribuíram esse aumento a menor esfericidade e a maior rugosidade da superfície dos grãos naturais.

2.3.2.4 Cor e composição mineralógica da partícula de sedimento transportado

A cor da partícula também pode causar variações na resposta do sensor, interferindo na detecção da luz dispersa na saída do sensor (DOWNING, 2006). Esse comportamento ocorre porque uma substância colorida absorve a energia em determinadas bandas do espectro, alterando as características da energia transmitida e dispersa; modificando, com isso, a proporção de luz que alcança o sistema de detecção do sensor (ANDERSON et al., 2010; SADAR, 1998).

Segundo Sutherland et al. (2000), partículas de coloração mais escura absorvem mais a energia incidente, de modo que o sinal registrado pelo sensor será menor se comparado aquele observado para partículas de coloração mais clara (Figura 6).

Figura 6 - Resposta do sensor OBS em função da CSS, para diferentes cores de sedimentos suspensos



Fonte: Sari, Castro e Kobiyama (2015). Elaborada a partir de resultados reportados por Sutherland et al. (2000)

Já no referente à composição mineralógica da partícula, Maa e Xu (1992) analisaram a performance do sensor OBS para três tipos de sedimentos coesivos (Caulinita, Ilita e Montmorilonita), concluindo que, apesar do sensor responder linearmente à concentração de sedimentos, a faixa operacional (limite de leitura do sensor) varia em função da mineralogia analisada: entre 0 e 0,5 g/L para a Caulinita, entre 0 e 0,8 g/L para a Ilita e entre 0 e 1,2 g/L para a Montmorilonita. Essa faixa difere muito daquela prevista para materiais mais grosseiros, como silte e areia (em torno de 20 g/L). Isso ocorre porque, a quantidade de materiais finos em

suspensão (ou dos flocos gerados) é muito maior se comparada àquela resultante para os materiais silte e areia e, portanto, a intensidade de reflexão é mais elevada.

Os resultados desse estudo também demonstraram que o índice de refração do material tem fundamental importância na resposta emitida pelo sensor. A caulinita, por exemplo, apesar de possuir o maior diâmetro entre os três materiais analisados, possui, ao mesmo tempo, o maior índice de refração; o que gera maior reflexão da energia, reduzindo a faixa operacional do sensor (máxima turbidez observada para menores CSS).

Hatcher et al. (2000) mostraram que a declividade da função linear— que relaciona o coeficiente de retroespalhamento do sensor Hydroscat-6 e a quantidade de areia presente na amostra (coletadas em ambientes aquáticos)— difere significativamente para os diversos tipos de areia, conforme a composição (quartzo x carbonato) e a cor (quartzo natural x quartzo rosa) da amostra analisada. O sensor foi analisado para os comprimentos de onda 442, 470, 510, 589, 620, 671 nm da energia incidente. Os autores reportaram que as inclinações das linhas da função gráfica associadas à adição de areia carbonato são duas vezes mais altas que aquelas relacionadas à areia de quartzo natural e rosa, considerando o mesmo tamanho de partícula e o mesmo número de partículas por unidade de peso. Além disso, a declividade das linhas da amostra de areia composta por quartzo natural é significativamente mais elevada (em relação à linha da amostra de quartzo rosa) para os comprimentos de onda de 510 e 589 nm. Já para os comprimentos de 442 e 470 nm, essa diferença é bem menos significativa; enquanto que, para os comprimentos de onda de 620 e 670 nm, as linhas estão muito próximas, dificultando a diferenciação das amostras de quartzo natural e colorida.

2.3.2.5 Características ópticas e geométricas do sensor utilizado no monitoramento

O designer óptico do instrumento de monitoramento exerce forte influência na resposta registrada pelo sensor (LEWIS e EADS, 2009), podendo causar alterações da ordem de 10 vezes na saída do sensor (DOWNING, 2006). Os resultados de uma oficina realizada, em 2002, durante o “*Federal Interagency Workshop on Turbidity and Other Sediment Surrogates*” demonstraram que os valores de turbidez registrados por diferentes instrumentos, para uma dada CSS, podem ser altamente variáveis e estão, frequentemente, em desacordo; mesmo quando o método de calibração é semelhante (GRAY e GLYSSON, 2002).

De maneira geral, dois ou mais instrumentos, com diferentes geometrias de emissão e detecção da luz incidente, não produzem resultados equivalentes de turbidez, para uma mesma

CSS; ainda que o processo de calibração realizado seja muito próximo (ANDERSON, 2005; ANDERSON et al., 2010).

Análises efetivadas por Foster, Millington e Grew (1992)— utilizando os turbidímetros Partech S100 e S1000—, por exemplo, mostraram variações significativas nos valores de turbidez registrados pelos diferentes sensores, considerando uma mesma CSS e sedimentos oriundos de um mesmo local. Da mesma forma, resultados reportados por Merten, Capel e Minella (2014) para os sensores Solar SL 2000-TS, DTS-12 e YSI 6136, utilizando sedimentos coletados em High Island Creek (St. Peter, Minnesota, EUA), mostraram que a resposta dos sensores varia de acordo com as características dos instrumentos empregados, considerando a mesma CSS e o mesmo tamanho da partícula.

Algumas vezes, sensores de mesmo modelo (e, portanto, com as mesmas propriedades ópticas e geométricas) podem também resultar em repostas diferentes, considerando uma mesma CSS e tamanho da partícula de sedimento. Isso em razão das características de estabilidade do instrumento e de sua capacidade de identificação do sinal, as quais podem decair ao longo do tempo, durante a operação em campo.

Calibrações realizadas em laboratório (Figura 5), para três sensores DTS-12 semelhantes (mesmo modelo e fabricante), demonstraram respostas diferenciadas, para as mesmas variações da CSS e o mesmo tamanho da partícula de sedimento (SARI, CASTRO e KOBAYAMA, 2015). A análise estatística realizada, no entanto, evidenciou que não existem diferenças significativas, a um nível de significância de 5%, entre as leituras médias dos três sensores, para as diferentes classes granulométricas testadas (SARI et al., 2017).

Diante desse contexto, há que se considerar que esse problema pode ser minimizado com uma verificação periódica da estabilidade de leitura e da calibração do instrumento de monitoramento. O fabricante do instrumento DTS-12 utilizado nessa pesquisa (*Forest Technology System*), por exemplo, sugere que o equipamento tenha sua estabilidade de leitura verificada após um ano de funcionamento em campo.

Kleizen et al. (1995) verificaram, ainda, que o ângulo de detecção da energia escolhido também afeta a leitura de um sensor. Os autores utilizaram um sensor com leituras simultâneas a 12° e 90° para avaliar a influência do ângulo de detecção da luz na captação da energia dispersa pelas partículas. Nesse sentido, Merten, Capel e Minella (2014) observaram que sensores com ângulo de detecção da energia refletida na posição 90° (DTS-12 e YSI 6136) mostram maior sensibilidade para identificação de uma ampla faixa de variação do diâmetro das partículas, em comparação com sensores posicionado a 180° (solar SL 2000-TS).

A esse respeito, é relevante apontar que a grande maioria dos sensores nefelométricos utiliza um ângulo de detecção da luz a 90° (exemplo: DTS-12 e YSI 6136), que além de ser menos sensível a variações do tamanho da partícula, proporciona um sistema óptico simples, com baixa difusão da energia (menor quantidade de luz difusa). A presença da luz difusa pode ser uma fonte significativa de erro para pequenos valores de turbidez, já que essa luz, apesar de atingir o detector de um sistema óptico, não provém da amostra. Logo, existe uma interferência positiva na turbidez medida (SADAR, 1998).

Outro fator que influencia a resposta do sensor é o comprimento de onda da luz emitida pelo instrumento. Isso porque a distribuição espacial da luz dispersa depende da relação entre o tamanho da partícula e o comprimento de onda da luz emitida. Uma diminuição do caminho percorrido pela luz através da amostra reduz o número de partículas entre a fonte de luz e o detector de luz, e conseqüentemente, estende o limite superior da medição da turbidez (SADAR, 1998).

Hatcher et al. (2000) analisaram o coeficiente de retroespalhamento do sensor Hydroscat-6 para seis comprimentos de onda (442, 470, 510, 589, 620 e 671 nm) e diferentes composições (quartzo e carbonato) e tamanhos de partículas de areia (100% de areia com diâmetro igual a 300 μm ; 100% de areia com diâmetro de 180 μm ; 75% de areia com 180 μm + 25% de areia com 300 μm ; 50% de areia com 180 μm + 50% de areia com 300 μm ; e 25% de areia com 180 μm + 75% de areia com 300 μm). Os autores concluíram que o coeficiente apresenta uma variação linear em função do aumento da quantidade de areia na amostra, mas a declividade da função gráfica difere de um comprimento de onda para outro. Eles verificaram ainda, que essas diferenças de inclinação foram significativas (a um nível de significância de 95%) para as misturas contendo um único tamanho de grão (180 ou 300 μm).

2.3.2.6 Presença de bolhas, gases e outros componentes na coluna de água

A presença de bolhas e gases na coluna de água pode causar uma turbidez aparente, gerando valores maiores do que aqueles que estão realmente ocorrendo em um dado meio aquático (ANDERSON, 2005). As bolhas de ar causadas por fluxos turbulentos, por exemplo, podem gerar ruídos de alta frequência sobre os registros de turbidez. Sendo que a amplitude das oscilações comumente aumenta com o aumento do fluxo (LEWIS e EADS, 2009).

Sobre esse aspecto, Downing, Sternberg e Lister (1981) descreveram um pequeno deslocamento positivo (não quantificado) na resposta do sensor OBS, devido à presença de

bolhas; o que, contudo, não teria representado alterações significativas no ganho/sensibilidade do instrumento e na sua correlação com a concentração de sedimentos. Os autores utilizaram areia de praia, variando a CSS entre 0,1 e 100 ppt.

Black e Rosenberg (1994) ao relatarem a influência do arrastamento de bolhas de ar associadas à agitação rápida da amostra, também identificaram um aumento do sinal medido pelo sensor OBS (entre 5 e 10%) em comparação com aquele verificado para a condição de água parada. Todavia, conforme os autores, o efeito dessa incorporação de ar *in situ* seria menos significativo do que aquele verificado em laboratório.

Da mesma forma, Clifford et al. (1995) observaram variações do sinal lido pelo sensor IR40-C em função da presença de ar em uma amostra de água; descrevendo a ocorrência de poucos efeitos quando as bolhas possuem até 0,15 cm, e efeitos mais significativos na presença de bolhas maiores. Contrariamente, ensaios realizados por Puleo et al. (2006), utilizando areia e lama, mostraram maior resposta do sensor OBS quando as bolhas de ar apresentavam pequeno diâmetro e grande concentração. Além disso, o aumento do sinal foi mais pronunciado para a água salgada quando comparada à água doce.

De maneira semelhante, a presença de microrganismos em suspensão (principalmente fitoplâncton), poluentes e matéria orgânica também interferem na difusão da energia entre as partículas e o sensor (MINELLA et al., 2008; RASMUSSEN et al., 2011; SCHOELLHAMER e WRIGHT, 2003). Aparentemente, águas claras e com matéria biológica suspensa, podem apresentar maior retroespalhamento (e menor transmissão) se comparadas a águas puras; ainda que esses materiais sejam praticamente negligenciáveis em concentração de massa ($\mu\text{g/L}$). A presença de plâncton, por exemplo, pode aumentar a resposta de transmissômetros e sensores OBS em até quatro vezes quando comparada a concentrações semelhantes de grãos minerogênicos (BUNT, LARCOMBE e JAGO, 1999).

De fato, Schoellhamer (1993) identificou a existência de maior correlação entre a resposta do sensor OBS e a clorofila do que entre a CSS e a saída do sensor OBS (R de 73% em comparação com 50%), em monitoramento realizado em Tampa Bay (Flórida, EUA). Segundo o autor, o fitoplâncton, que continha clorofila, influenciou a resposta do sensor tanto quanto a presença de sedimentos; principalmente quando a CSS estava próxima ou logo abaixo do limiar de resposta desse sensor. Além disso, existiram picos na saída do sensor, ocasionados pela natação dos peixes em frente ao instrumento, o que afetou a média das leituras. Entretanto, essa interferência foi minimizada pela utilização da mediana como representativa da resposta

do sensor. Houve ainda, um aumento na saída do sensor em função do acúmulo de algas na superfície óptica; o que revelou a necessidade de limpezas diárias do instrumento.

Em locais com altas cargas de nutrientes, temperaturas amenas e sol abundante, podem ocorrer incrustações biológicas, rápidas e frequentes, nas janelas de sensores ópticos (LEWIS e EADS, 2009). Essas incrustações resultam em falsos valores de turbidez para uma escala temporal, já que mantém os valores medidos ao longo do dia ou por dias seguidos; principalmente em regiões mais quentes, onde a atividade microbiológica é mais elevada (ANDERSON et al., 2010).

O acúmulo gradual de sedimentos, algas, ou resíduos finos sobre a janela óptica do sensor gera uma turbidez gradualmente achatada ou aumentada; mesmo que a vazão esteja retrocedendo ou já em baixa. Por outro lado, quando o sensor está limpo, a turbidez decai repentinamente. Geralmente, essas incrustações progressivas podem ser evitadas por meio da implantação de sensores que utilizem um método mecânico de limpeza da superfície óptica (LEWIS e EADS, 2009). Todavia, caso ocorra o crescimento de algas filamentosas próximas ao campo óptico do sensor, a contaminação pode estar fora do alcance do limpador, e ainda assim decorrer em leituras errôneas, devido às ondulações que as direcionam para frente do sensor. Nesse caso, é aconselhável que se proceda a retirada manual desses materiais (LEWIS e EADS, 2009) por ocasião das visitas de rotina.

2.3.2.7 Processos de floculação, agregação e turbulência

O efeito dos processos de floculação, agregação e turbulência pode aumentar as incertezas nas respostas do sensor, interferindo nas leituras efetuadas pelo instrumento (MINELLA et al., 2008; RASMUSSEN et al., 2011; SCHOELLHAMER e WRIGHT, 2003). As alterações ocasionadas podem alcançar a ordem de 2 vezes sobre a saída do sensor (DOWNING, 2006).

Os processos de floculação natural, que ocorrem nos regimes laminares, podem aglomerar partículas que seriam individualmente mais eficientes na dispersão da luz, formando agregados com menor eficiência (DOWNING, 2006), o que resulta em menor leitura do sensor óptico. Já os escoamentos mais turbulentos possuem maior capacidade de transporte das partículas e uma capacidade de floculação e agregação mais reduzida, além de proporcionar maior formação de bolhas de ar e a introdução de gases no líquido.

A floculação ocorre quando as partículas de sedimento ou flocos entram em contato e se juntam (EISMA, 1991), sendo uma função da concentração de partículas e também da turbulência (DOWNING, 2006). A formação de flocos pode ser facilitada em alguns escoamentos turbulentos devido ao aumento da colisão entre as partículas; entretanto, em níveis mais elevados de turbulência, os flocos tendem a ser quebrados em partículas menores. Por outro lado, a presença de compostos orgânicos, formando revestimentos sobre os grãos, colabora para a manutenção da união das partículas sob a forma de flocos (EISMA, 1991).

As partículas podem, por sua vez, serem postas em contato por meio de processos físicos (tais como: a turbulência e a sedimentação diferencial), pelo movimento browniano (movimento aleatório de partículas microscópicas imersas em um fluido, originado pelo choque das moléculas do fluido nessas partículas microscópicas), ou pela existência de partículas muito pequenas, da ordem de vários microns (EISMA, 1991). Por isso, o grau de floculação é maior para lodos finos e argilas (BUNT, LARCOMBE e JAGO, 1999). A frequência desse contato dependerá do mecanismo que o provocou, do tamanho da partícula e da sua concentração (EISMA, 1991).

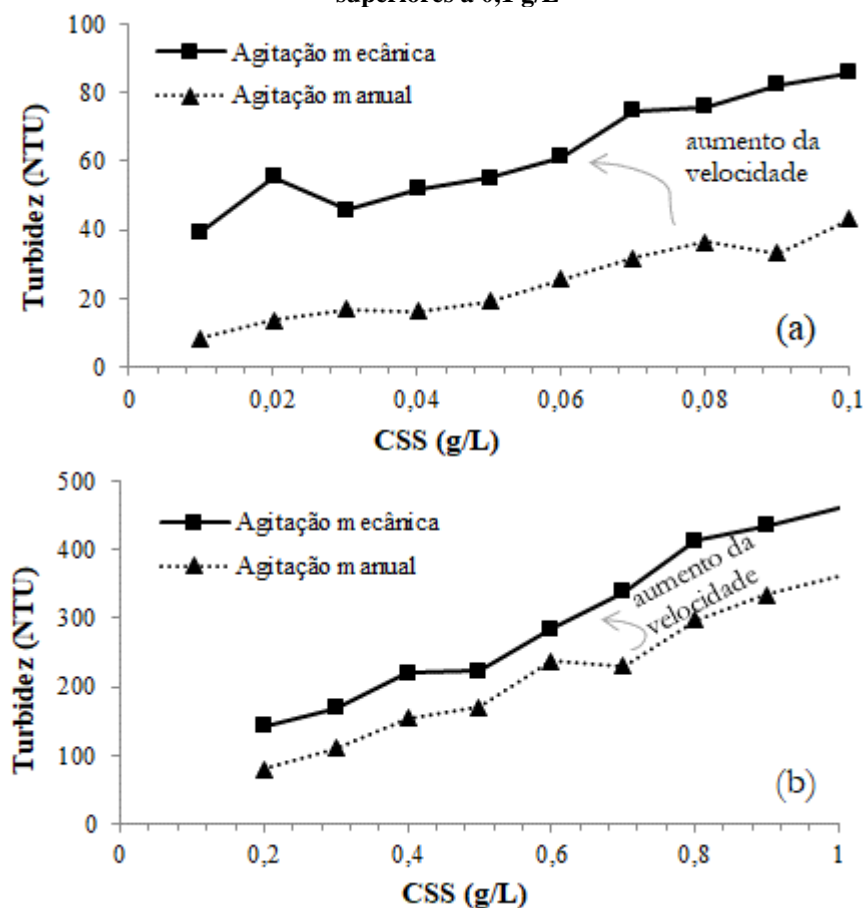
O tamanho dos flocos é um grande controlador da resposta dos instrumentos ópticos e pode variar temporal e espacialmente, conforme forem as condições hidrodinâmicas atuantes. Com isso, a dispersão da luz pelos flocos é extremamente complexa; principalmente, porque o processo de desagregação de partículas maiores em menores pode alterar o retroespalhamento da energia, modificando a resposta do sensor (BUNT, LARCOMBE e JAGO, 1999).

Gibbs e Wolanski (1992) utilizaram caulinita comercial (com diâmetro médio igual a 1,5 μm) e uma amostra (água-sedimento) com turbidez máxima, retirada do rio Fly (Papua, Nova Guiné), com diâmetro médio igual a 3,5 μm , para investigar a influência da formação de flocos na resposta de um sensor óptico-nefelométrico (Modelo 156, McVan Instruments, Victoria, Austrália). Para a amostra contendo caulinita, os resultados demonstraram que o escoamento de maior velocidade (velocidade máxima de 100 cm/s), produz maior intensidade de retroespalhamento para uma dada CSS. Isso porque, os flocos formados eram muito pequenos e não havia uma abundância de partículas primárias. Por outro lado, quando as mesmas amostras foram submetidas a escoamentos mais lentos (10 a 12 cm/s), com maior possibilidade de floculação, a intensidade de resposta do sensor decaiu consideravelmente. Uma intensidade de 1 V, por exemplo, correspondeu a uma CSS igual a 2 g/L para um fluxo de alta velocidade e 5 g/L para um fluxo de menor velocidade. Os resultados obtidos da amostra do rio Fly apresentaram um comportamento muito semelhante aquele obtido para a caulinita. Nesse

caso, uma CSS igual 5 g/L correspondeu a uma resposta do sensor de 1,23 V, para a condição de alta turbulência e, em torno de 10 g/L para um escoamento mais lento.

Ensaio realizados por Sari, Castro e Kobiyama (2015) no Laboratório de Sedimentos do IPH/UFRGS, utilizando agitação manual e mecânica das amostras, demonstram que o aumento da turbulência gera uma elevação da resposta do sensor DTS-12, para uma mesma CSS e mesmas características das partículas de sedimento. Na Figura 7 são apresentadas as variações da resposta do sensor DTS-12 em função das características da agitação da amostra, considerando agitação mecânica e manual.

Figura 7 - Variação da resposta do sensor DTS-12 em função das condições de agitação da amostra: (a) turbidez para concentrações de sedimento suspenso (CSS) entre 0,01 e 0,1 g/L e; (b) turbidez para CSS superiores a 0,1 g/L

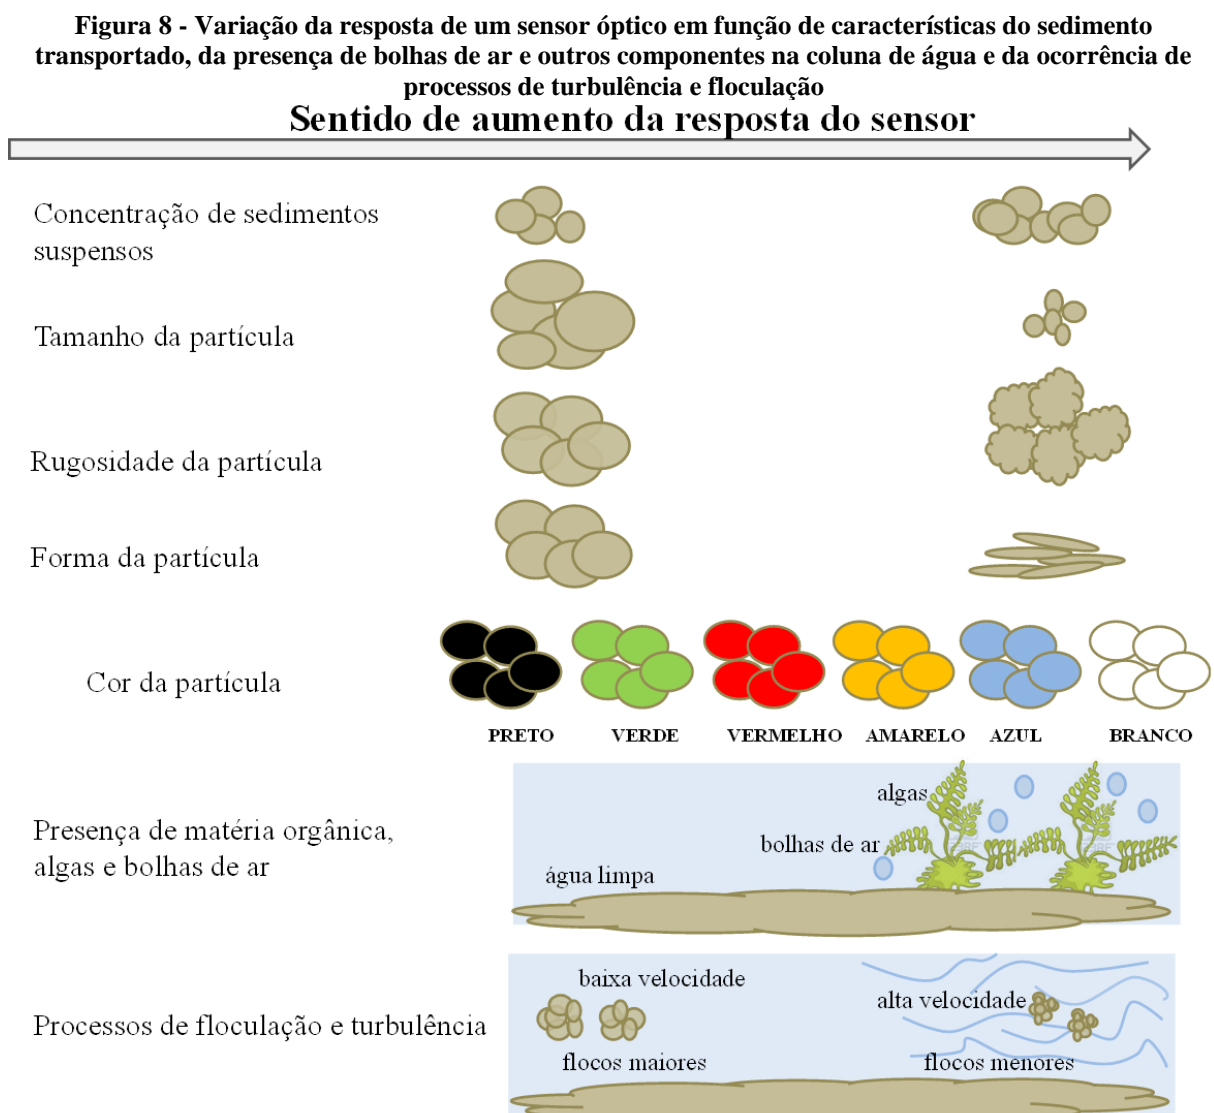


Fonte: Sari, Castro e Kobiyama (2015)

As amostras foram coletadas na bacia do Taboão (Pejuçara, RS), sendo o processo manual de agitação realizado durante três minutos utilizando-se uma jarra com misturador acoplado (metodologia empregada por SARI et al., 2012). Após esse período, o processo de agitação foi interrompido e a sonda foi inserida na amostra para realização das leituras de turbidez. Por outro lado, na agitação mecânica a amostra ensaiada foi submetida ao processo de

agitação durante todo o tempo de leitura do sensor. No processo manual, quando cessada a agitação, desenvolvem-se condições favoráveis à formação de flocos e à decantação das partículas mais grosseiras; enquanto que no processo mecânico, a turbulência impede ou minimiza a formação de flocos, além de facilitar a ocorrência de bolhas de ar na mistura. Tais características resultaram em uma resposta mais elevada do sensor de turbidez para a agitação mecânica, em comparação à saída do sensor para o método de agitação manual.

A Figura 8 apresenta uma síntese da variação da resposta de um sensor óptico, em função dos fatores anteriormente descritos.



Fonte: Sari, Castro e Kobiyama (2015)

Observa-se então que, em termos gerais, a resposta do sensor será tanto maior quanto:

- i) maior for a CSS para um mesmo diâmetro da partícula, ii) menor for o tamanho da partícula,
- iii) maior for a rugosidade da partícula, iv) mais alongada ou coloidal for a forma da partícula,

v) menos escura for a partícula de sedimento transportado, vi) maior for a quantidade de material biológico presente, vii) mais turbulento for o fluxo (formação de flocos de menor dimensão), e viii) maior for a quantidade de bolhas de ar presentes no meio líquido.

2.3.3 Aplicações de sensores ópticos como medida indireta da CSS: o cenário brasileiro

A aplicação dos sensores ópticos como tecnologia alternativa para determinação da CSS é, ainda, uma técnica bastante incipiente no cenário brasileiro. A maioria dos estudos que empregaram tais tecnologias foi realizada em bacias hidrográficas localizadas na região sul do Brasil (Tabela 3).

Em geral, a relação entre a resposta do sensor e a CSS foi elaborada tendo por base um curto período de dados de monitoramento, variando de alguns dias (eventos) a menos de um ano. Como comparativo, pode-se dizer que estudos desenvolvidos em outros locais (ver Tabela 1) comumente empregam um período maior para a calibração dos instrumentos de monitoramento (1 ano ou mais, podendo chegar a 8 anos), com R^2 reportado entre 0,6 e 0,998.

Todavia, há que se considerar que tais locais geralmente aplicam sistemas de monitoramento mais eficientes, somados a leis rígidas de controle da qualidade das águas e, por isso, apresentam bancos de dados maiores para construção das curvas de calibração. No Brasil, a rede de monitoramento da produção/transporte de sedimentos e da qualidade da água é pequena, o que se torna um limitante para o desenvolvimento de calibrações mais representativas e também, para futuras modelagens dos processos hidrossedimentológicos.

Por outro lado, esse cenário também revela que o desenvolvimento de sistemas mais eficientes de monitoramento da qualidade das águas brasileiras, bem como a preservação dos recursos hídricos e o planejamento adequado do uso de tais recursos, perpassa pela implantação de tecnologias alternativas de monitoramento, como os sensores ópticos. Tais tecnologias possibilitarão a construção de um banco de dados com informações contínuas, com maior facilidade de aquisição das informações e a um custo relativamente baixo. As informações obtidas, por sua vez, poderão facilitar a elaboração de inúmeros projetos de engenharia e possibilitar a melhoria dos processos de modelagem da qualidade da água e do transporte de sedimentos em bacias hidrográficas brasileiras.

Tabela 3 - Descrição de estudos realizados no Brasil utilizando sensores ópticos como medida indireta da CSS

Autor	Local	Sensor (resolução/λ)	Período calibração	Tipo de ajuste	Função	NS/R²/R
Vestena, Lucini & Kobiyama (2007)**	bacia de Caeté (Alfredo Wagner, Santa Catarina)	Solar SL 2000-TS (0-2500 NTU/700-3x10 ⁵ ηm)	23/11/2005 (26 amostras de solo)	polinomial	CSS=0,0006X ² + 2,4231X - 276,54 (X em mV, CSS em mg/L)	R²=0,9993
Carvalho, Paranhos & Paiva (2004)	bacia Menino Deus II e Alto da Colina II (Santa Maria, RS)	sonda de turbidez (não especificada)	Menino Deus II: 10 meses (agosto/01-junho/02) Alto da Colina II: 11 meses (junho/01-maio/02)	linear	Menino Deus II: CSS= 0,046.T ^{1,53} (T<527 NTU) Alto da Colina II: CSS = 0,0624.T ^{1,5295} (T<505 NTU)	R²=0,765 R²=0,73
Minella et al. (2008)*	bacia de Arvorezinha (Arvorezinha, RS)	Solar SL 2000-TS (0-2500 NTU/700-3x10 ⁵ ηm)	campo: eventos coletados em 8 dias (15/07, 20/09, 22/09 e 23/10/04; 01/04, 11/05, 18/05 e 20/05/05)	potencial	campo: CSS=0,098.T ^{2,313} lab: CSS=0,569.T ^{2,039} (T em % e CSS em mg/L)	R²=0,84 R²=0,807
Lopes et al. (2009)	bacia do Capão Comprido (Distrito Federal)	Solar SL 2000-TS (0-2500 NTU/700-3x10 ⁵ ηm)	-	linear	CSS= 0,0006.T + 0,0046 (T<390 NTU) CSS= 0,0014.T - 0,1646 (T>390 NTU)	R²=0,9239 R²=0,9084
Manz, Santos & Paula (2010)	bacia do rio Sagrado (Serra do Mar, Paraná)	DTS-12 (0-1600 NTU/780 ηm)	13 amostras em diferentes condições de vazão	linear	CSS=1,2481.T-3,6393	R²=0,976
Pereira, Paiva & Pereira & Paiva (2012); Pereira & Paiva (2010)	bacias Rancho do Amaral e Rinção do Sotumo (entre Itaara e Santa Maria, RS)	Solar SL 2000-TS (0-2500 NTU/700-3x10 ⁵ ηm) DTS-12 (0-1600 NTU/780 ηm)	Rinção do Sotumo: ~ 4,5 meses (07/08/2009 a 29/12/2009) Rancho do Amaral: ~4,5 meses (29/09/09 a 11/01/2010)	linear	Rinção do Sotumo: CSS= 0,7278 . T - 19,98 Rancho Amaral: CSS= 0,5602 . T + 4,1413	R²=0,71 R²=0,76
Poletto et al. (2011)	rio São Francisco Falso (Paraná)	turbidímetro (não especificado)	14 dias (entre novembro e dezembro/06, e entre janeiro e fevereiro/07)	potencial	Q _{ss} = 51,52 Ln(T) - 101,62 (Q _{ss} em m³/dia e T em Volts)	-
Cardoso, Kobiyama & Grison (2012)	bacia do rio Bugres (Santa Catarina)	DTS-12 (0-1600 NTU/780 ηm)	janeiro a junho/12 (10 amostras)	linear potencial	CSS = 1,1118.T + 1,9092 CSS = 2,4086.T ^{0,7509}	R²=0,9711 R²=0,8512
Sari et al. (2012)	bacias do Taboão (Tb), Turcato (Tc) e Donato (Dn), localizadas em Pejuçara (RS)	DTS-12 (0-1600 NTU/780 ηm)	amostras de sedimento suspenso coletadas durante vários meses nos exutórios das bacias	polinomial, potencial, e linear	Tb: CSS=4,191.E ⁻⁴ .T ² +2,594.T-11,726 Tc: CSS=2,492.T ^{1,067} (CSS>100 mg/L) e CSS=3,323.T-0,142 (CSS≤100 mg/L) Dn: CSS=3,031.T ^{1,032} (CSS>100 mg/L) e CSS=3,757.T-13,747 (CSS≤100 mg/L)	Tb: R²=0,975 Tc: R²=0,97 (>100) e 0,981 (≤100) Dn: R²=0,952 (>100) e 0,909 (≤100)
Pinheiro et al. (2013)	seção da Aroeira, rio Umbuzeiro (Aiuaba, Ceará)	DTS-12 (0-1600 NTU/780 ηm)	amostras coletadas em lago e posteriormente diluída	cúbica	CSS=-6x10 ⁻⁷ .T ³ +0,0013.T ² +0,6306.T-5,4136 (T em NTU e CSS em mg/L)	R²=0,9999
Bartel, Terra & Collares (2014)	bacia do Arroio do Ouro (entre Pelotas e Morro Redondo, RS)	sensor de turbidez localizado em uma estação hidrossedimentológica (SOLAR)	~5,5 meses (16/04 a 02/10/14)	polinomial linear	polinomial: CSS=0,0023.T ² + 2,5953.T-37,706 linear: CSS=4,5439.T+178,6	R²=0,9992 R²=0,9852
Brasil et al. (2014)	Bacia Experimental de Iguatu (Ceará)	OBS-300 (0 ~4000 NTU/ 850 ηm)	8 dias (9 a 16/05/13)	polinomial	CSS= 7.E ⁻⁰³ .T ² + 0,3523.T-10,093	R² = 0,9892
Teixeira et al. (2016)	estação João Goulart, bacia do rio Vacacai Mirim, Santa Maria (Rio Grande do Sul)	turbidímetro (0-1600 NTU)	96 amostras coletadas em diferentes eventos ocorridos entre 2 de setembro e 6 de outubro de 2014	potencial	CSS=0,833.T ^{1,2266}	R²=0,7400

Q_{ss}= descarga de sedimentos, CSS= concentração de sedimentos suspensos, T=turbidez

* calibração realizada em: i) laboratório, utilizando sedimentos suspensos coletados por torpedo na seção do rio (lab); ii) campo, a partir de eventos monitorados (campo)

** Calibração realizada em laboratório a partir de 26 amostras de solo coletadas na bacia

Quando não especificado: T em NTU e CSS em mg/L

calibração realizada em laboratório

Fonte: Adaptado de Sari, Castro e Kobiyama (2015)

As relações de calibração (entre a resposta do sensor e a CSS) usualmente empregadas em estudos brasileiros são do tipo linear, polinomial ou potencial, com R^2 variando entre 0,71 e 0,999. Apesar dos autores reportarem um ajuste satisfatório, a grande maioria deles não faz menção a posteriores verificações em campo das curvas de calibração elaboradas.

Assim, podem existir restrições em relação à utilização dessas equações para transformação da saída do sensor em CSS, sobretudo, porque o período utilizado na calibração é relativamente pequeno, podendo haver limitações na representatividade das variações temporais e espaciais da dinâmica do transporte de sedimentos.

De fato, a pequena amplitude dos dados pode tornar-se um fator limitante se existir grande variabilidade temporal das características das partículas de sedimento transportadas, tendo-se em consideração os diferentes regimes hidrológicos atuantes. Especialmente importantes são as variações no tamanho da partícula, nas proporções das frações granulométricas transportadas e na quantidade de material transportado sob as diferentes vazões registradas ao longo dos anos (ou dentro do ano). Além disso, pode também haver variações na quantidade de material fino disponibilizado para transporte, a partir das áreas drenadas da bacia, de acordo com o período do ano considerado na calibração. Nesse caso, conforme a estação do ano e as vazões utilizadas, a relação elaborada entre a resposta do sensor e a CSS estaria limitada a algumas condições específicas de regime e do tipo de material transportado.

Dessa forma, entre os desafios para a implantação e para a aplicabilidade dos sensores ópticos como medida indireta da CSS no Brasil, estão: i) a aquisição de maior período de dados para elaboração das curvas de calibração; ii) a investigação da aplicabilidade dos sensores ópticos nas demais regiões brasileiras; iii) a identificação dos fatores de maior influência sobre a resposta do sensor, em cada local de monitoramento e para cada tipo de instrumento e; quando necessário, a elaboração de curvas específicas, por regime atuante e época do ano; e iv) o relacionar das informações obtidas pelos sensores ópticos a outras variáveis e parâmetros de qualidade da água e também, a outras tecnologias alternativas para monitoramento da CSS.

Estudo realizado por Carvalho, Paranhos e Paiva (2004) mostra que o tamanho da partícula de sedimento transportado e a proporção de material presente (areia, silte e argila), podem ser características importantes na construção de relações de ajuste turbidez-CSS em rios brasileiros. Ao realizar o monitoramento da turbidez em duas pequenas bacias do rio Vacacaí Mirim, no município de Santa Maria/RS, os autores observaram que o ajuste elaborado foi comprometido quando proporções significativas de areia estavam presentes. Desse modo, a aplicação da curva de calibração elaborada foi limitada a valores de turbidez inferiores a 505 e

527 NTU, para as bacias de Alto da Colina II e Menino Deus II, respectivamente. Para a bacia de Menino Deus II, o monitoramento foi realizado entre agosto de 2001 e junho de 2002, resultando em um ajuste com $R^2=0,765$ ($CSS=0,046.T^{1,53}$). Já para a estação Alto da Colina II, o período estendeu-se de junho de 2001 a maio de 2002, sendo o R^2 obtido de 0,73 ($CSS=0,0624.T^{1,5295}$).

Assim sendo, entre os fatores que se espera exercer maior influência sobre a resposta dos sensores ópticos estão, conforme as características dos rios e bacias hidrográficas brasileiras: a CSS, o diâmetro da partícula, a proporção granulométrica do material transportado, e a forma da partícula de sedimento. Em algumas bacias pode ser também importante os componentes presentes na coluna de água e os processos de turbulência.

Desse modo, sempre que possível, indica-se a consideração de tais fatores no processo de calibração dos instrumentos, com averiguação da necessidade da elaboração de diferentes curvas de calibração, conforme as características das partículas transportadas durante os diferentes regimes atuantes. Quando inviável, recomenda-se (ao menos) uma avaliação minuciosa da existência de variações dos diâmetros das partículas transportadas sob os diferentes regimes hidrológicos; e ainda, da possibilidade de grandes variações da disponibilidade de fornecimento de sedimento e de suas propriedades durante determinadas épocas do ano.

Sugere-se também que, quando viável, os dados utilizados para a calibração dos instrumentos abarquem o maior período possível (um ano ou mais), a fim de que se possa considerar a variabilidade temporal e espacial das características do sedimento transportado sob os diferentes regimes hidrológicos, e as alterações na quantidade de material disponibilizado para transporte nas calhas dos rios.

Da mesma maneira, é importante uma avaliação da presença de nutrientes e outros componentes na coluna de água, particularmente, para aquelas bacias caracterizadas como rurais. Nessas bacias, pode existir uma periodicidade da presença de determinados componentes, em função das fases de crescimento da planta e da aplicação de alguns produtos específicos sobre as culturas agrícolas (exemplo: adubos e fertilizantes). Tais produtos podem alterar a resposta do sensor, além de facilitar a proliferação de algas e outras plantas que, por sua vez, interferem positivamente nas leituras efetuadas pelo instrumento. Na maioria das vezes, a utilização de sensores com sistema de limpeza automática é suficiente para atenuar essa interferência. Limpezas periódicas da superfície óptica do sensor por ocasião das visitas de rotina *in situ* também são ferramentas importantes nesse quesito.

Portanto, quando as características dos sedimentos transportados e a disponibilidade/proporção de material forem muito variáveis, ou ainda, quando a limpeza dos sensores não puder ser realizada e a influência dos componentes presentes na coluna de água for muito significativa, a aplicabilidade dos sensores ópticos pode ser muito comprometida, inviabilizando sua utilização como medida alternativa da CSS.

Além disso, é essencial destacar a necessidade de elaboração de relações específicas entre a resposta do sensor e a CSS, considerando cada tipo de instrumento e local em que os sensores serão implantados; uma vez que os fatores limitantes dependerão das características sobressalientes no local considerado em associação às propriedades do instrumento. Igualmente importante é a verificação periódica da necessidade de aferição dos sensores ópticos, em razão de problemas ocasionados pela perda da estabilidade dos instrumentos; medida que poderá garantir a representatividade das curvas de calibração elaboradas.

Por fim, cabe salientar que a importância da consideração da influência de todos os fatores já descritos sobre a resposta de um sensor óptico, confirma que a calibração do instrumento realizada *in situ* é a forma mais eficiente de se construir uma adequada relação entre a resposta do sensor e a CSS. Nesse caso, maiores serão as chances de se obter uma relação que pondere a interferência conjunta de tais fatores sobre a saída do sensor e, por conseguinte, mais representativos serão os valores da CSS obtidos a partir da relação construída.

A interferência desses fatores na leitura dos sensores ópticos, somadas as dificuldades da coleta de amostras em número suficiente para a confecção de relações estatísticas, também sugere que a adoção de um modelo não linear para determinação da CSS poderá mostrar-se mais efetivo. E dentro desse cenário, o emprego de RNAs pode ser uma alternativa interessante, em função de sua grande capacidade de aprendizado e generalização, e também, devido sua forte habilidade de aprender e reconhecer relações não-lineares, e de organizar dados dispersos em modelos não-lineares; possibilitando a construção de modelos não-lineares mais representativos.

2.4 A modelagem como ferramenta para análise da dinâmica hidrossedimentológica

Os modelos hidrossedimentológicos são ferramentas computacionais que possibilitam entender e representar o comportamento de uma bacia hidrográfica, permitindo avaliar os efeitos dos agentes ambientais e das alterações antrópicas sobre os processos hidrológicos, de desagregação, de transporte e de deposição de sedimentos.

Usualmente, os modelos podem ser classificados conforme: i) os processos físicos simulados e os algoritmos que descrevem esses processos: empíricos e conceituais (semi-conceituais e de base física); ii) a escala espacial representada: concentrado, semi-distribuído e distribuído; iii) a resolução temporal simulada: contínuo ou evento e; iv) os dados e parâmetros requeridos: determinístico ou estocástico (MERRITT, LETCHER e JAKEMAN, 2003; DANIEL et al., 2011).

De maneira geral, as informações utilizadas durante a simulação de um modelo compreendem dados hidrometeorológicos (precipitação, neve, temperatura, radiação, umidade, pressão de vapor, horas de sol, velocidade do vento e evaporação); agrícolas (cobertura vegetal, uso do solo, tratamentos e fertilizantes aplicados); pedológicos (tipo de solo, textura e estrutura, condições do solo, diâmetro da partícula, porosidade, teor de umidade, pressão capilar, infiltração no estado de equilíbrio, condutividade hidráulica saturada e teor de umidade antecedente); geológicos (dados acerca da estratigrafia, litologia e estruturas de controle, além de informações sobre o tipo, profundidade e extensão dos aquíferos); geomorfológicos (áreas drenadas, elevação, rede de drenagem, declividade e área da bacia); hidráulicos (rugosidade, tipo de escoamento, seção transversal do rio e morfologia do rio) e hidrológicos (profundidade do escoamento, descarga, escoamento de base, escoamento subsuperficial, interação fluxo-aquífero, potencial, lençol freático e rebaixamentos de nível) (SINGH e FREVERT, 2002, 2006).

Entre as principais restrições dos modelos destacam-se a quantidade e a qualidade dos dados de entrada requeridos, a dificuldade em formular matematicamente alguns processos e a simplificação do comportamento espacial de variáveis e fenômenos (TUCCI, 2005).

A análise de sensibilidade dos parâmetros do modelo pode atenuar os erros relativos às entradas requeridas, limitando o número de parâmetros a ser obtido *in situ* àqueles de maior significância para o modelo; o que possibilita melhor ajuste entre os dados simulados e observados, e melhor representação das condições reais do sistema (GREEN e VAN GRIENSVEN, 2008). A análise de sensibilidade também identifica os parâmetros mais sensíveis, que ditam o conjunto de parâmetros a ser utilizado no subsequente processo de calibração (KANNAN et al., 2007).

A calibração dos parâmetros de entrada, a partir de dados observados em campo, também pode minimizar os erros decorrentes das simulações. Todavia, é preciso considerar que tais valores são válidos somente para as condições analisadas no modelo e para as características

do local estudado. Assim sendo, as aplicações em outros locais e as comparações com outros estudos precisam ser analisadas criteriosamente quanto à similaridade das condições.

É necessário considerar, ainda, os erros decorrentes das condições iniciais do modelo, geralmente desconhecidas. Por isso, a simulação é comumente realizada com valores iniciais transientes, os quais requerem algum tempo para alcançar o estado de permanência. Essa dificuldade pode ser contornada mediante a realização de uma simulação prévia durante um período de tempo T, conhecido por período ou tempo de aquecimento do modelo. Esse período representa uma parcela específica do tempo de simulação, durante o qual os dados resultantes dessa simulação não são considerados, em virtude da transiência das condições iniciais. Quanto menor for o período de simulação maior importância terá o tempo necessário para se alcançar o equilíbrio dos valores iniciais (NEITSCH et al., 2002, 2005, 2011).

Na previsão da erosão e da produção de sedimentos podem ser utilizados modelos como: ANSWERS (*Areal Nonpoint Source Watershed Response Simulation*), EUROSEM (*EUROpean Soil Erosion Model*), USLE (Equação Universal de Perda de solo), KINEROS2 (*KINematic EROsion Simulation 2*), LISEM (*Limburg Soil Erosion Model*), WEEP (*Water Erosion Prediction Project*), WESP (*Watershed Erosion Simulation Program*), SWAT (*Soil And Water Assessment Tool*), etc.

Algumas informações relevantes acerca de modelos para estimativa da erosão e do transporte de sedimentos, bem como de modelos de qualidade da água podem ser encontradas em estudos realizados por: Zhang, O'Neill e Lacey (1996); Singh e Woolhiser (2002); Summer e Walling (2002); Borah e Bera (2003, 2004); Merritt, Letcher e Jakeman (2003); Parsons, Thomas e Huffman (2004) e Aksoy e Kavvas (2005).

A USLE é o modelo empírico mais utilizado no Brasil [e também em diversas outras regiões do mundo], para a previsão das perdas de solo médias anuais e para o planejamento e a gestão do uso do solo (CARVALHO, 2008). Essa equação foi originalmente projetada para subsidiar ações de planejamento de uso do solo pelos conservacionistas americanos, sendo representada apenas numericamente e calculada com base em dados meteorológicos e pedológicos.

A equação envolve os seis principais fatores que afetam a erosão, causada pela água (ação da chuva e escoamento superficial), em solos localizados em áreas declivosas: a erosividade das chuvas, a erodibilidade do solo, a extensão das encostas e a declividade [representam o fator topográfico], as técnicas de gestão e cultivo [uso e manejo do solo], e as práticas de conservação (WISCHMEIER e SMITH, 1965, 1978).

Wischmeier e Smith (1965, 1978) apresentaram a USLE com a forma da equação 1:

$$A = R.K.L.S.C.P \quad (1)$$

Onde: A- é a perda de solo por unidade de área e tempo (t/ano ou outra unidade, dependendo das que forem utilizadas nos parâmetros); R- é o fator de erosividade da chuva, expressando a erosão potencial ou o poder erosivo da precipitação média anual da região, considerando um ano de condições normais (t.m/ha.mm/h); K- é o fator de erodibilidade do solo, representando a capacidade do solo de sofrer erosão por ação de uma determinada chuva (t/ha/(tm/ha.mm/h)); L- é o fator topográfico que expressa o comprimento do declive (m); S- é o fator topográfico que representa a declividade do terreno ou o grau do declive; C- é o fator que expressa o uso e o manejo do solo e a cultura; P- é o fator que representa a prática conservacionista do solo.

Os parâmetros “R” e “K” são determinados a partir de extensas pesquisas de campo. Para a aplicações práticas da equação, os fatores “L” e “S” são considerados conjuntamente, como um fator topográfico “LS” (CARVALHO, 2008).

O fator “LS” é a relação esperada de perdas de solo, por unidade de área, em um declive qualquer, em relação às perdas de solo correspondentes de uma parcela unitária de 25 m de comprimento e 9% de declive (CARVALHO, 2008).

O fator de uso e manejo do solo “C” é a relação esperada entre as perdas de solo de um terreno cultivado em dadas condições e as perdas correspondentes de um terreno mantido continuamente descoberto e cultivado (CARVALHO, 2008).

Williams (1975) propôs uma modificação na USLE, para eventos chuvosos isolados, substituindo o fator R da USLE pelo produto de um fator de volume de escoamento superficial e da vazão de pico do hidrograma de cheia, dando uma nova forma à equação, que ficou conhecida como MUSLE (Equação Universal de Perda de Solo Modificada), apresentada na equação 2:

$$A = a(Q_s \cdot q_p)^b \cdot K.LS.C.P \quad (2)$$

Onde: A- é a produção de sedimentos na bacia devido a uma chuva individual (t/ha); Qs- é o volume de escoamento superficial (m³); Qp- é a vazão de pico do escoamento superficial (m³/s); K, L, S, C, P- são os fatores da USLE; a, b - são coeficientes calibrados para cada bacia. Na MUSLE original, os coeficientes da equação 8 são a=11,8 e b=0,56 (WILLIAMS, 1975), para o Sistema Internacional.

Os fatores K , LS , C e P são obtidos de tabelas e de dados topográficos da bacia de interesse e; Q_s e q_p são geralmente estimados por modelagem dos processos chuva-vazão (WILLIAMS, 1975).

2.4.1 Modelos de funções explícitas para determinação da concentração de sedimentos suspensos (CSS)

Usualmente, a definição da CSS é realizada, de maneira indireta, através do ajuste de modelos de funções explícitas, que relacionam a CSS à vazão (e, portanto, ao nível de água) e/ou à turbidez.

Em geral, o ajuste mais empregado entre vazão-CSS é do tipo potencial (KISI, 2012; RAJAEI et al., 2011; RAJAEI 2011; MUHAMMADI, AKBARI e AZIZZIAN, 2012; SHIRI e KISI 2012; BOUKHRISSE et al., 2013; GHORBANI et al., 2013; LIU et al., 2013; OLYAIE et al., 2015), sendo também empregadas equações obtidas por regressões lineares (MELESSE et al., 2011; RAJAEI, 2011; RAJAEI et al., 2011; BOUKHRISSE et al., 2013), frequentemente utilizando dados diários de vazão, precipitação ou ainda, a vazão de um e/ou dois dias anteriores.

Já as equações ajustadas entre turbidez-CSS são habitualmente do tipo linear (TENA et al., 2011; ABE et al., 2012; BUSCHMAN et al., 2012; CHIKITA et al., 2012; MARTTILA e KLOVE, 2012; PEREIRA, PAIVA e PAIVA, 2012; HARRINGTON e HARRINGTON; 2013; HAIMANN et al., 2014; SLAETS et al., 2014), embora também sejam descritos ajustes do tipo potencial (MINELLA et al., 2008; POLETTI et al., 2011; ZIEGLER et al., 2014) ou polinômio de segunda ordem (FINLAYSON, 1985; OLD et al., 2003; NAVRATIL et al., 2011) e, em alguns casos, polinômios de terceira ordem (PINHEIRO et al., 2013, BAYRAM, KANKAL e ÖNSOY, 2012; BAYRAM et al., 2014).

Uma função matemática representada por uma fórmula conhecida pode ter seus parâmetros ajustados para minimizar uma função que representa os erros (chamada função objetivo), usualmente, a soma do quadrado dos erros. Um ponto de mínimo desta função objetivo possui as seguintes propriedades: i) as derivadas primeiras em relação aos parâmetros procurados são zero e; ii) a matriz das derivadas segundas (matriz Hessiana), avaliadas no ponto de mínimo, é positivo-definida; ou seja, a função quadrática que aproxima a função original neste ponto tem seu mínimo também neste ponto.

No caso das funções lineares, pode-se utilizar o método dos mínimos quadrados, o qual consiste na resolução das “equações normais”, que resultam da minimização da soma dos

quadrados dos erros, igualando-se a zero a derivada desta função em relação aos parâmetros. Porém, para funções não lineares e que não podem ser transformadas em equações lineares, necessita-se de técnicas mais abrangentes para o ajuste de seus parâmetros, como os métodos iterativos de minimização da função objetivo.

O método de Newton resulta de uma expansão de segunda ordem com série de Taylor da função objetivo F , cuja derivada em relação à variação dos parâmetros é igualada a zero, para representar a condição de um ponto estacionário, resultando na equação 3:

$$p_n = [H_n]^{-1} \nabla F(x_n), \quad n \geq 0 \quad (3)$$

Onde: H_n representa a matriz Hessiana, composta das derivadas segundas para cada parâmetro pesquisado; $\nabla F(x_n)$ representa as derivadas primeiras e; $p_n (=x_{n+1} - x_n)$ é a direção da pesquisa dos parâmetros.

A principal limitação do método de Newton é o esforço computacional, a cada iteração, para o cálculo da matriz Hessiana, que nem sempre é disponível analiticamente, e para o cálculo da sua inversa.

As alternativas ao método de Newton, para contornar estas limitações, são os métodos quase-Newton de otimização, nos quais ou a matriz Hessiana ou a sua inversa é aproximada continuamente, utilizando as variações dos gradientes entre iterações. Os vários métodos quase-Newton diferem-se pela escolha da solução para esta atualização, a cada iteração, uma vez que esta não possui uma única solução.

O método quase-Newton mais efetivo (NOCEDAL, 2006) é o algoritmo BFGS (BROYDEN, 1970; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970). Neste método, a matriz inversa da matriz Hessiana ($B=H^{-1}$) é inicializada pela matriz identidade ($B_0=I$), sendo atualizada a cada interação, por uma modificação da matriz B_n , da interação anterior, de forma a ser simétrica, positivo-definida e não mudar drasticamente entre duas iterações sucessivas. Resulta que a atualização da inversa da matriz Hessiana é feita pela equação 4:

$$B_{n+1} = (I - \rho_n \delta_n \phi_n^T) B_n (I - \rho_n \phi_n \delta_n^T) + \rho_n \delta_n \delta_n^T \quad (4)$$

Onde:

$$\phi_n = \nabla F(x_{n+1}) - \nabla F(x_n) \quad (5)$$

$$\delta_n = \gamma_n p_n \quad (6)$$

$$\rho_n = \frac{1}{\phi_n^T \delta_n} \quad (7)$$

Outra vantagem computacional deste método, é que, em vez de resolver um sistema de equações lineares ou uma inversão de matriz para a determinação, a cada interação n , da direção de procura, realiza-se um simples produto (equação 8):

$$p_n = -B_n \nabla F(x_n) \quad (8)$$

Uma vez calculada a direção de procura, executa-se uma procura linear na direção p_n , pelo valor de γ_n que minimiza a função objetivo $F(x_n + \gamma_n p_n)$, para, a seguir, calcular $x_{n+1} = x_n + \gamma_n p_n$

As principais condições de finalização do procedimento de procura, que devem ser estabelecidos previamente, são, além do número máximo de iterações, os limites de variação da função objetivo ($|F(x_{n+1}) - F(x_n)|$) e dos próprios parâmetros ($|x_{n+1} - x_n|$) entre duas iterações sucessivas.

2.4.2 As redes neurais artificiais (RNAs) e a previsão da concentração de sedimentos suspensos (CSS)⁵

As RNAs são modelos estatísticos (HU e HWANG, 2002) e empíricos (ASCE, 2000), que imitam o funcionamento do cérebro humano, possuindo características em comum com as redes neurais biológicas (FAUSETT, 1994; ASCE, 2000; HAYKIN, 2001). Essas redes apresentam elevada potencialidade de ajuste de funções não-lineares, mediante a introdução de um conjunto de entradas e saídas desejadas, reconhecendo padrões entre as variáveis mesmo na presença de falhas ou ruídos.

Entre suas principais características estão: as habilidades de adaptação, de aprendizado, de generalização (KRÖSE e SMAGT, 1996; KASABOV, 1998), de separação e organização de dados (KRÖSE e SMAGT, 1996); a robustez; o armazenamento associativo das informações; o grande paralelismo e; o processamento espaço-temporal das informações (KASABOV, 1998).

A rede aprende extraindo informações de uma amostra de observações de entrada e suas saídas correspondentes (aprendizado/treinamento da rede), e generaliza através de sua capacidade de resposta a situações ainda não encontradas durante o processo de aprendizagem (verificação da rede). A capacidade de generalização de uma RNA é influenciada por: i) o

⁵ Texto construído com base no artigo:

SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017. <https://doi.org/10.1007/s11269-017-1785-4>

OLIVEIRA, M.H.C. de; SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, v. 62, n. 13, p. 2120-2138, 2017. DOI: 10.1080/02626667.2017.1364844

tamanho da amostra de treinamento e a representatividade dos dados; ii) a arquitetura da rede e; iii) a complexidade física do problema modelado (HAYKIN, 2001).

Nos últimos anos, modelos baseados em RNAs ou associados a essas redes têm atraído pesquisadores da área de sedimentologia, evidenciando que essas redes podem ser uma alternativa viável e promissora para a predição da CSS (ver estudos descritos no APÊNDICE A). Por outro lado, essas redes não são bons extrapoladores e, por isso, a amostra de treinamento deve cobrir todo o domínio desejado (FREEMAN e SKAPURA, 1991) para as simulações (inclusive as futuras), exigindo grande quantidade de dados para desenvolvimento dos modelos treinados pelas técnicas tradicionais.

Uma RNA é composta por elementos de processamento simples chamados neurônios, que recebem e modificam os sinais recebidos e os transmitem, sucessivamente, por meio de conexões de ligação. Essas conexões possuem pesos a elas associados, representando a força da conexão (ASCE, 2000). Cada neurônio é constituído por: i) uma função de transferência, geralmente linear, que executa uma soma ponderada das entradas e; ii) uma função de ativação, linear ou não linear, que executa a transformação da entrada ponderada em um valor de saída do neurônio (HU e HWANG, 2002).

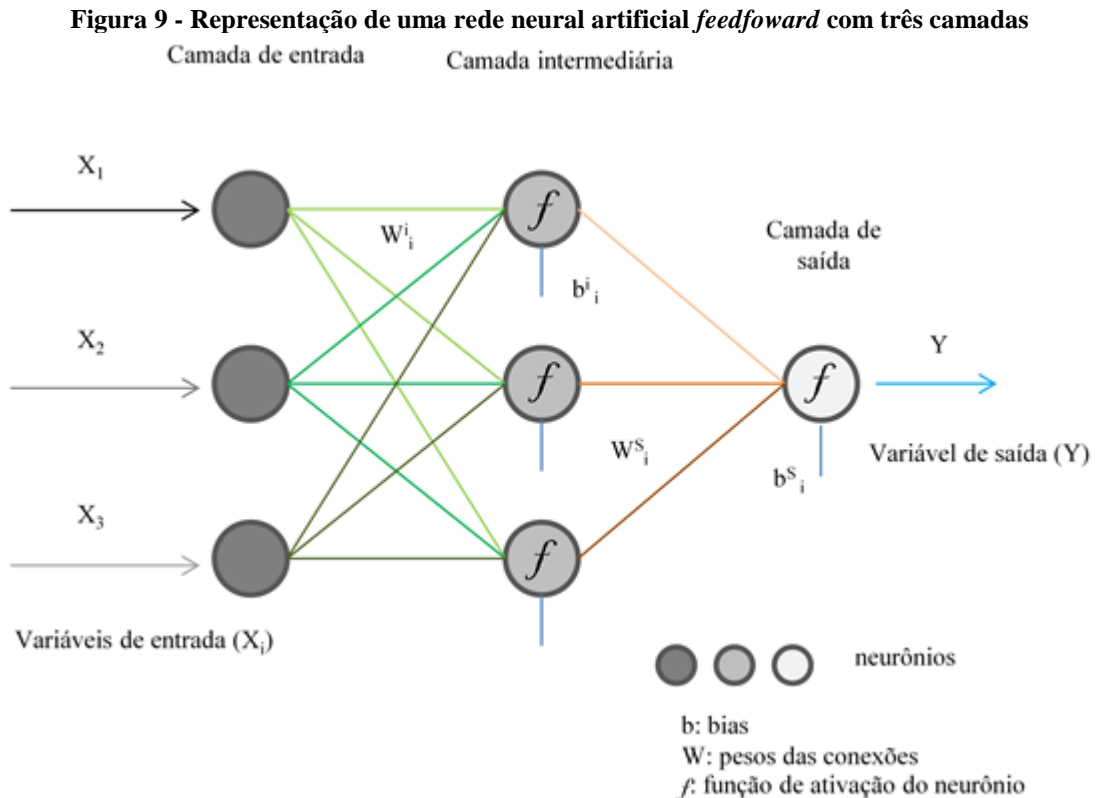
Nas aplicações hidrossedimentológicas, comumente utiliza-se uma RNA do tipo *feedforward* (ou progressiva) (RUMELHART, HINTON e WILLIAMS, 1986), em geral com uma estrutura de três camadas (Figura 9, ver estudos descritos no APÊNDICE A) (SINGH e FREVERT, 2006). Essas redes possuem neurônios agrupados em camadas, sendo que o sinal percorre a rede em uma única direção, da entrada para a saída e os neurônios da mesma camada não são conectados.

A rede neural *feedforward*, com uma ou mais camadas intermediárias, é um aproximador universal de grande precisão (HORNIK, STINCHCOMBE e WHITE, 1989); tendo sido utilizada, eficientemente, em diferentes aplicações.

A primeira camada é constituída apenas das entradas de dados. Nas camadas sucessivas, cada neurônio recebe a soma, ponderada por coeficientes chamados de pesos sinápticos (em analogia às redes neurais naturais), das entradas enviadas pelos neurônios da camada anterior, adicionadas a um termo de tendência (*bias*). Esse valor passa por uma transformação linear ou não linear (função de ativação do neurônio), que transforma esta soma em um valor de saída desta camada, para constituir a entrada da camada subsequente, ou a saída da rede (RUMELHART, HINTON e WILLIAMS, 1986). O funcionamento de um neurônio é definido pela equação 9:

$$O = f(\sum_{i=1}^n w_i I_i + b) \quad (9)$$

Onde: O é o valor da resposta do neurônio; f é a função de ativação; w_i são os pesos sinápticos; I_i são os valores das n entradas que serão processadas no neurônio e b é a tendência ou *bias*.



Fonte: autora

A forma mais utilizada para a função de ativação dos neurônios da camada intermediária é a função sigmoide unipolar, em razão da simplicidade de sua derivada. Também pode ser utilizada a função sigmoide bipolar. Pode-se ainda utilizar para os neurônios da camada de saída, uma função de ativação do tipo linear (HU e HWANG, 2002; SINGH e FREVERT, 2006), para resultarem saídas na escala desejada. Entretanto, o uso de funções não lineares (sigmóides) para a saída, com escalonamento posterior (FANTÍN-CRUZ et al., 2011; OLIVEIRA, PEDROLLO e CASTRO, 2011), como a função sigmoide, aumenta a capacidade do modelo para aproximar comportamentos não-lineares.

A equação 10 apresenta o formato da função sigmoide unipolar e a equação 11 representa a derivada desta função:

$$f(\eta) = \frac{1}{1+e^{-\eta}} \quad (10)$$

$$f'(\eta) = f(\eta)(1 - f(\eta)) \quad (11)$$

Onde: η é a entrada líquida do neurônio, definida como o resultado de $w_i I_i + b$.

A fórmula para a derivada (equação 11), dependente apenas dos resultados da função $f(\eta)$, apresenta importantes vantagens, uma vez que, na sequência do algoritmo de treinamento, esse resultado já será conhecido quando ocorrer o cálculo da derivada.

Os pesos sinápticos das conexões e o *bias* são ajustados através do treinamento da rede, que consiste em modificações desses parâmetros, por intermédio de uma regra de aprendizado, com o objetivo de minimizar uma medida de desempenho, baseada nos erros entre a saída da rede e o valor observado (ASCE, 2000). Os valores iniciais dos pesos e do *bias* devem ser pequenos e escolhidos aleatoriamente (FREEMAN e SKAPURA, 1991; KASABOV, 1998). Além disso, o treinamento deve ser executado mais de uma vez (diversas iterações), a partir de pesos aleatórios diferentes, escolhendo-se a configuração de pesos sinápticos com melhor desempenho, pois, devido a esta aleatoriedade, cada treinamento pode resultar uma rede distinta.

O método de treinamento mais utilizado em RNAs (ASCE, 2000) é o algoritmo retropropagativo (RUMELHART, HINTON e WILLIAMS, 1986) (ver estudos descritos no APÊNDICE A), uma generalização da Regra Delta proposta por Widrow e Hoff (1960), a qual é uma técnica de procura de um ponto de mínimo da superfície de desempenho formada pelos erros quadráticos, perfazendo um caminharmento no sentido oposto ao do gradiente da superfície em um ponto (WIDROW e HOFF, 1960).

Os passos para a aplicação da regra delta são a execução da rede, com os pesos atuais, o cálculo dos erros, pela comparação com os resultados esperados e das derivadas da função de ativação, e a atualização dos pesos segundo a equação 12, em ciclos sucessivos de aplicação da regra com o conjunto de amostras disponibilizadas para o treinamento.

$$w_{k+1} = w_k - \tau e_k \delta_k I_k \quad (12)$$

Onde: w_k são os pesos sinápticos dos neurônios; τ é a taxa de aprendizagem; δ_k é a derivada das funções ativação; e I_k são as entradas na própria camada, no ciclo k .

O emprego dessa regra para o treinamento das camadas internas da rede requer o conhecimento dos erros (e_h) nessa camada, calculados pela equação 13 (RUMMELHART, HINTON e WILLIAMS, 1986). De acordo com essa equação, os erros das camadas anteriores dependem somente dos erros e das propriedades das camadas posteriores.

$$e_h = \sum (W_{h+1} e_{h+1} \delta_{h+1}) \quad (13)$$

Onde: e_h é o erro na camada interna considerada; W_{h+1} , e_{h+1} e δ_{h+1} são, respectivamente, os pesos sinápticos, os erros e as derivadas na camada seguinte.

O método retropropagativo recebeu aperfeiçoamentos, como as técnicas heurísticas de aceleração do treinamento, entre as quais a conjugação da aplicação de um termo de inércia (momento) com a variação heurística da taxa de aprendizado, proposta por Vogl et al. (1988). O termo de inércia, proposto para RNAs originalmente por Rumelhart, Hinton e Williams (1986), consiste em um filtro para reduzir as oscilações, conferindo estabilidade ao procedimento de procura, proporcional às diferenças observadas na evolução recente dos pesos. A variação da taxa, por sua vez, é feita em função da variação do desempenho, aumentando-se o passo quando o erro anterior é maior do que o atual, ou reduzindo-se o passo quando aquele erro é menor.

Quando o número de neurônios na camada intermediária for excessivo, ou ainda, quando o número de ciclos executados é muito grande, pode ocorrer o treinamento excessivo da rede, caracterizado pelo ajuste também das aleatoriedades presentes na amostra de treinamento (HECHT-NIELSEN, 1990). O número excessivo de ciclos gera grande capacidade de memorização dos dados utilizados no treinamento, porém resulta em menor capacidade de generalização para uso da rede em um conjunto de dados não utilizado durante o treinamento. Por outro lado, um número insuficiente de ciclos pode ocasionar a incapacidade da rede em representar os dados de saída desejados, pois o treinamento não foi completado (BASHEER e HAJMEER, 2000).

O controle do superajustamento é feito pela limitação da complexidade do modelo (número de neurônios nas camadas internas), ou pela interrupção oportuna do treinamento resultante de condições suficientes de finalização, que resultam da análise dos efeitos sobre uma amostra diferente da utilizada no treinamento. Porém, como a amostragem de verificação, necessária para o teste posterior da capacidade de generalização, não pode ter participado em nenhuma etapa dos procedimentos de definição da arquitetura da rede neural, nem de seu treinamento (HECHT-NIELSEN, 1990), é necessário o uso de outro conjunto amostral, chamado de amostragem de validação. Assim sendo, são necessários para o procedimento de treinamento, validação e verificação da RNA realizar a divisão da amostra de dados disponível em três conjuntos distintos de dados.

A técnica mais empregada para divisão da amostra, quando existem registros de dados suficientes, requer três conjuntos amostrais (Treinamento, Validação e Verificação), sendo conhecida por validação cruzada para redes neurais (HECHT-NIELSEN, 1990). A validação cruzada utiliza, portanto, uma amostra não usada no treinamento, para executar uma avaliação do erro, ao longo do treinamento. O início do superajustamento ocorre no ciclo no qual o erro

da série de validação começa a aumentar, enquanto o erro da série de treinamento continua a diminuir. Assim, a validação cruzada funciona como um determinante do momento ideal de parada do treinamento, já que a estatística de erros do treinamento vai sempre diminuindo (indicando desempenho melhor), enquanto que a estatística de erros da série de validação, a partir de determinado ciclo, volta a elevar-se, indicando que um limiar foi atingido. Esse limiar determina o momento a partir do qual a capacidade de generalização fica comprometida, devendo-se, nesse ponto, interromper o treinamento (HECHT-NIELSEN, 1990).

Quando o número de informações disponíveis (N) for severamente limitado, pode-se usar a forma extrema do método da validação cruzada, conhecido como *leave-one-out method* (Método Validação Cruzada n-Fold). Nesse caso, N-1 exemplos são utilizados para treinar o modelo, e o modelo é validado testando-o sobre o exemplo deixado de fora. O experimento é repetido para um total de N vezes, cada vez deixando de fora um exemplo diferente para a validação (HECHT-NIELSEN, 1990).

Outro ponto a ser considerado no desenvolvimento de modelos baseados em RNAs é o escalonamento dos registros das variáveis de entrada e de saída. O escalonamento das variáveis de saída permite a generalização do domínio do modelo, uma vez que as saídas das funções de ativação não lineares são, via de regra, limitadas, e o uso da função de ativação linear reduziria a capacidade de aproximação da rede neural. O escalonamento das entradas, por sua vez, deve ser realizado quando existem mais de um atributo de entrada, com magnitudes diferentes; isso porque a técnica retropropagativa de treinamento premia as maiores entradas, negligenciando o treinamento dos demais pesos sinápticos, o que poderia ocasionar a não convergência para a solução desejada.

Dessa forma, o escalonamento dos dados possibilita a igualdade de importância das diferentes entradas, durante o processo de treinamento da RNA, evitando a convergência mais rápida junto aos nós com dados de maior magnitude (KASABOV, 1998). Essas transformações comumente constituem simples transferências lineares de escala, já que a complexidade das relações não lineares é aproximada pela própria RNA.

As variáveis frequentemente empregadas como entradas das RNAs desenvolvidas para previsão sedimentológicas são, em ordem da maior utilização para a menor (ver estudos descritos no APÊNDICE A): i) vazão ou nível de água, ii) CSS ou outros fatores relacionados à sedimentologia, como produção de sedimento, iii) precipitação, iv) temperatura, v) parâmetros relacionados à geomorfologia e qualidade da água ou ainda, vi) características obtidas de imagens de satélite.

Após determinadas as características da rede e executado o treinamento com validação cruzada, a RNA deverá passar por um processo de teste (verificação), com utilização de uma série ainda não usada no treinamento (conforme já mencionado anteriormente), para identificação de sua capacidade de generalização.

Em geral, os modelos de RNAs desenvolvidos internacionalmente apresentam desempenhos de elevada eficiência (ver estudos descritos no APÊNDICE A), tanto no treinamento quanto na verificação; demonstrando que, de fato, as RNAs podem ser uma alternativa promissora para a obtenção de modelos mais representativos nas estimativas sedimentológicas, se comparados às tradicionais relações vazão-CSS comumente empregadas.

No entanto, há que se destacar que modelos baseados em RNAs exigem uma grande quantidade de dados para o treinamento, validação e verificação das redes construídas, de tal forma que as informações utilizadas sejam representativas de todo o domínio a ser pesquisado/simulado (inclusive o horizonte futuro).

Tal característica poderia ser um fator limitante para o desenvolvimento de estudos empregando tais recursos em bacias hidrográficas brasileiras, tendo-se em vista que as pesquisas em nosso país usualmente caracterizam-se por monitoramentos de pequeno período (Tabela 3), sobretudo, em razão da limitação dos recursos disponíveis. Essa realidade enaltece a importância de se desenvolver metodologias alternativas para a construção de modelos baseados em RNAs, que possibilitem a construção de redes eficientes a partir do emprego de menores quantidades de informações de entrada.

2.4.3 A modelagem dos processos hidrossedimentológicos com o *Soil And Water Assessment Tool* (SWAT)

O SWAT é um modelo do tipo físico, distribuído, de simulação contínua, que opera em um passo de tempo diário, embora possibilite a utilização de subintervalos. Ele foi desenvolvido pelo Departamento de Agricultura dos Estados Unidos (NEITSCH et al., 2002, 2005, 2011) e possibilita a simulação de inúmeros processos em uma bacia hidrográfica, entre eles: a hidrologia, a meteorologia, os sedimentos, a temperatura do solo, o crescimento da cultura, os nutrientes, os pesticidas e o manejo agrícola (BORAH et al., 2006). Para tal, o SWAT requer a entrada de informações de clima, propriedades do solo, topografia, vegetação e práticas agrícolas, presentes na bacia (NEITSCH et al., 2002, 2005, 2011).

O SWAT é capaz de analisar os impactos que as práticas de manejo e as alterações do uso do solo e da vegetação provocam sobre o escoamento (superficial e subterrâneo), a

produção de sedimentos e a qualidade da água em bacias hidrográficas. Como saída pode-se visualizar hidrogramas e sedimentogramas, distribuídos na bacia. O modelo também possibilita a simulação dos efeitos das mudanças climáticas, mediante a manipulação dos dados de entrada lidos pelo programa (NEITSCH et al., 2005).

A bacia hidrográfica é dividida em múltiplas sub-bacias, considerando um único curso de água por sub-bacia. Cada sub-bacia é subdividida em um número ilimitado de unidades de resposta hidrológica (*Hydrologic Response Units – HRU*), ou no mínimo em uma HRU. A HRU consiste em uma área, dentro da sub-bacia, caracterizada pelo mesmo uso e tipo de solo, mesmo manejo agrícola e classes de declividade (NEITSCH et al., 2010; ARNOLD et al., 2012a). Alternativamente, uma bacia hidrográfica pode ser subdividida unicamente em sub-bacias, definidas em função do tipo e manejo de solo e de seu uso dominante (GASSMAN et al., 2007).

Implícito no conceito das HRUs está o pressuposto de que não existe interação entre as HRUs de uma dada sub-bacia, ou seja, as cargas (escoamento de sedimentos, nutrientes, etc. transportados pelo escoamento superficial) de cada HRU são calculadas separadamente e depois somadas para determinar as cargas totais da sub-bacia. Caso a interação de uma área de uso do solo com outra seja importante, as áreas de uso do solo deverão ser definidas como sub-bacias, em vez de HRUs, pois é apenas no nível da sub-bacia que as relações espaciais podem ser especificadas (NEITSCH et al., 2010; ARNOLD et al., 2012a).

O SWAT considera o equilíbrio hídrico como a força motriz por trás de tudo o que ocorre na bacia hidrográfica. Portanto, a precisão no cálculo do transporte de pesticidas, sedimentos ou nutrientes vai depender do quanto o ciclo simulado é representativo daquilo que realmente ocorre na bacia. A simulação do ciclo é separada em duas fases: i) fase terrestre do ciclo hidrológico, onde existe o controle da quantidade de água, de sedimentos, de nutrientes e de pesticidas que chegam ao canal principal, em cada sub-bacia e; ii) fase aquática, em que ocorre a propagação do escoamento e dos poluentes através do canal principal da bacia até a sua saída (exutório) (NEITSCH et al., 2002, 2005, 2011).

A estrutura do modelo foi dividida em sete componentes: i) hidrologia (interceptação, infiltração, redistribuição da água no solo, evapotranspiração, escoamentos subsuperficial e superficial, armazenamento/reservatório, escoamento em canais principais e tributários, e vazão de base); ii) clima; iii) sedimentos; iv) crescimento vegetal; v) manejo agrícola; vi) nutrientes e; vii) pesticidas (NEITSCH et al., 2002, 2005, 2011).

O sistema hidrológico simulado é composto por quatro volumes de controle: i) reservatório superficial; ii) reservatório subsuperficial; iii) reservatório subterrâneo - aquífero

raso; e iv) reservatório subterrâneo - aquífero profundo. A contribuição destes reservatórios para o escoamento superficial provém do escoamento lateral, a partir do perfil de solo, e do escoamento de retorno do aquífero raso. O volume que percola do reservatório subsuperficial, através do perfil de solo, representa a recarga do aquífero raso. A água que percola para o aquífero profundo não retorna para o sistema (NEITSCH et al., 2002, 2005, 2011).

Os dados de entrada requeridos pelo modelo podem ser inseridos com o auxílio de uma interface gráfica do *software* GIS (ArcView[®] ou MapWindow[®]), sendo organizados em planos de informação cartográficos (PIs) e dados tabulares. Os PIs que devem alimentar o modelo correspondem a mapas de uso do solo, mapas pedológicos, hidrografia e o modelo numérico do terreno (MNT). Os dados de entrada necessários para cada sub-bacia estão agrupados nas categorias: clima; HRU; lagoas/zonas úmidas, água subterrânea, canal principal e seu alcance, drenagem das sub-bacias (NEITSCH et al., 2002, 2005, 2011).

A hidrologia terrestre é determinada por uma equação de balanço hídrico, considerando quatro processos principais: escoamento superficial, evapotranspiração, movimento da água no solo e água subterrânea. A subdivisão da bacia permite a representação dos valores evapotranspirados por cada uma das culturas e por cada tipo de solo presente na bacia (NEITSCH et al., 2002, 2005, 2011).

O clima da bacia hidrográfica fornece as entradas de umidade e de energia que controlam o equilíbrio da água, determinando a importância relativa dos diferentes componentes do ciclo hidrológico. As variáveis climáticas requeridas pelo modelo são: valores diários de: i) precipitação (ou sub-diários quando empregado o método de infiltração de Green & Ampt), ii) temperatura máxima e mínima do ar, iii) radiação solar, iv) velocidade do vento e v) umidade relativa do ar (NEITSCH et al., 2002, 2005, 2011).

O escoamento superficial é calculado utilizando o método CN do *Soil Conservation Service* (SCS) ou o método da infiltração de Green & Ampt. Quando o primeiro é utilizado, a interceptação já é considerada no cálculo do escoamento superficial e a infiltração é determinada pela diferença entre a quantidade de chuva e a quantidade escoada superficialmente. Quando o segundo método é utilizado, a interceptação é modelada separadamente, tendo por base a quantidade máxima que pode ser interceptada pela vegetação e o índice de área foliar. Já a infiltração é uma função do potencial matricial da frente de molhamento da superfície e da condutividade hidráulica efetiva. Esse método requer dados de precipitação em intervalos de tempo menores do que um dia (NEITSCH et al., 2002, 2005, 2011).

A vazão de pico é determinada por uma modificação do Método Racional, sendo uma função da quantidade precipitada (diariamente) durante o tempo de concentração (T_c) da sub-bacia, do volume diário de escoamento superficial e do tempo de concentração da sub-bacia. A porcentagem de precipitação que ocorre durante o T_c da sub-bacia é estimada como uma função da precipitação total diária, usando uma técnica estocástica. O T_c da sub-bacia é estimado pela fórmula de Manning, considerando o fluxo por terra e no canal (NEITSCH et al., 2002, 2005, 2011).

O modelo calcula a evaporação de solos e plantas separadamente. A evaporação potencial da água do solo é estimada em função da evapotranspiração potencial e do índice de área foliar. A evaporação real da água no solo é calculada a partir de funções exponenciais, considerando a profundidade do solo e o teor de água. A transpiração das plantas é simulada como uma função linear da evapotranspiração potencial e do índice de área foliar. A evapotranspiração potencial pode ser calculada por três equações: Hargreaves (HARGREAVES, HARGREAVES e RILEY, 1985), Priestley-Taylor (PRIESTLEY e TAYLOR, 1972), e Penman-Monteith (MONTEITH, 1965).

O escoamento subsuperficial lateral representa a contribuição da vazão que se origina abaixo da superfície, mas acima da zona onde as rochas estão saturadas. No perfil do solo (0-2 m), esse escoamento é calculado simultaneamente com a redistribuição. Um modelo de armazenamento cinemático é utilizado para prever o fluxo lateral, em cada uma das camadas do solo. Esse modelo é responsável por variações da condutividade, da declividade e do teor de água do solo (NEITSCH et al., 2002, 2005, 2011).

O fluxo de retorno ou o fluxo de base representa o volume de vazão proveniente de águas subterrâneas. O modelo SWAT particiona as águas subterrâneas em dois sistemas de aquíferos (NEITSCH et al., 2002, 2005, 2011): i) um aquífero freático raso, que contribui para o retorno dos fluxos ao rio dentro da bacia, e ii) um aquífero profundo, confinado, que contribui para o retorno dos fluxos ao rio fora da bacia (ARNOLD, ALLEN e BERNHARDT, 1993).

A água que percola abaixo da zona da raiz é dividida em duas frações, cada uma delas contribuindo para a recarga de um dos aquíferos. Além do fluxo de retorno, a água armazenada no aquífero raso pode repor a umidade no perfil do solo, quando ocorrem secas ou ainda, ser removida diretamente pela planta. A água nos aquíferos superficial e profundo também pode ser removida por bombeamento (NEITSCH et al., 2002, 2005, 2011). A percolação e o fluxo subterrâneo de retorno são calculados usando funções exponenciais, com parâmetros empíricos (BORAH et al., 2006).

A erosão e a produção de sedimentos são estimadas para cada HRU, com utilização da MUSLE (WILLIAMS, 1975). A MUSLE utiliza a quantidade de escoamento para simular a erosão e a produção de sedimentos. As condições de cobertura vegetal e de resíduos culturais são fatores essenciais para a estimativa do desprendimento e do transporte das partículas do solo. O crescimento diário das plantas é estimado usando uma versão simplificada do crescimento das plantas do modelo EPIC (NEITSCH et al., 2002, 2005, 2011).

Após a estimativa da produção de sedimentos, o modelo SWAT corrige o valor calculado considerando o atraso dos sedimentos carregados pelo escoamento superficial. O modelo também calcula a contribuição de sedimentos, no fluxo do canal, a partir de fontes subterrâneas e laterais (NEITSCH et al., 2005).

Uma vez que as cargas (água, sedimentos, nutrientes e pesticidas) que chegam ao canal principal tenham sido determinadas pelo modelo SWAT, elas são encaminhadas pela rede de drenagem da bacia. Esse movimento no canal principal pode ser dividido em quatro componentes: água, sedimentos, nutrientes e produtos químicos e/ou orgânicos (NEITSCH et al., 2002, 2005, 2011).

O fluxo de água transportado está sujeito a perdas por ação da evaporação e transmissão quando o canal não recebe água do escoamento profundo, ou ainda, pela retirada de água para agricultura ou consumo humano. Além disso, é possível a introdução de água durante o transporte em função de chuvas precipitadas diretamente sobre o canal e/ou pela ação de pontos de descarga de água. A rotina de transporte da água no canal (fluxo superficial, subsuperficial, lateral e de base) pode ser realizada pela utilização do Método de Muskingum (BRAKENSIEK, 1967; OVERTON, 1966) ou pelo método de Williams (WILLIAMS, 1969), também conhecido como Método da Acumulação Variada (NEITSCH et al., 2005, 2011).

Já o sedimento é encaminhado através do canal considerando a ocorrência simultânea de processos de deposição e degradação. A máxima quantidade de sedimento que pode ser transportada em cada seção do canal é uma função da velocidade de pico nesse canal. A energia do curso d'água disponível é utilizada para retransportar o material solto que está depositado, até que todo o material seja removido. O excesso de energia no curso de água ocasiona a degradação do leito, sendo essa degradação ajustada para a cobertura e erodibilidade do leito do rio (NEITSCH et al., 2002, 2005, 2011).

Quando a concentração de sedimentos no canal, no início do passo de tempo, é maior que a quantidade máxima de sedimentos calculada, ocorre deposição. Por outro lado, caso a concentração de sedimentos no canal, no início do passo de tempo, seja menor que a quantidade

máxima de sedimentos calculada, a degradação passa a ser o processo dominante. A proporção das perdas e deposições do sedimento transportado depende da força do escoamento. Forças de escoamento excessivas poderão ocasionar degradações no leito do canal (NEITSCH et al., 2002, 2005, 2011).

2.4.3.1 Análise de sensibilidade, calibração e verificação

Frequentemente, os modelos distribuídos apresentam um grande número de parâmetros de entrada, o que dificulta o desenvolvimento dos processos de calibração. Definir quais parâmetros afetam mais as respostas de um modelo requer uma análise de sensibilidade desse modelo.

A análise de sensibilidade possibilita identificar os parâmetros de entrada que têm maior efeito, quantitativo e qualitativo, sobre a saída do modelo (FEYEREISEN et al., 2007); permitindo estabelecer o conjunto de parâmetros mais sensível, que deverá ser utilizado no processo de calibração (KANNAN et al., 2007).

Na prática, esse procedimento procura definir os parâmetros que contribuem mais fortemente para a geração das respostas do modelo, de forma que, na etapa de calibração do modelo, os parâmetros identificados como de menor sensibilidade sejam desconsiderados no processo de calibração (CARVALHO, 2014). Essa análise pode ser realizada de forma local ou global (SINGH e WOOLHISER, 2002).

Nas técnicas locais, as respostas do modelo são analisadas variando-se cada parâmetro enquanto fixam-se todos os demais. São então observadas as influências de cada variação sobre a saída e o desempenho do modelo, principalmente mediante a construção de análises gráficas. Esse processo é realizado para cada um dos parâmetros de entrada do modelo. Essa é uma forma rápida de análise, com menor exigência computacional; entretanto, não é possível se ter a certeza de que os valores dos parâmetros mantidos fixos sejam os mais adequados (ARNOLD et al., 2012b).

Por outro lado, no método global, todos os dados de entrada são variados simultaneamente, permitindo-se investigar a possível interação da variação de todos os parâmetros de entrada sobre os resultados do modelo. A análise de sensibilidade global é efetuada com a utilização de algoritmos complexos, construídos para esse fim. Contudo, por necessitar de várias simulações, essa técnica apresenta como desvantagem maior exigência computacional (CARVALHO, 2014). Ela é uma alternativa interessante, na medida em que facilita o processo de avaliação de um grande número de parâmetros; embora, um usuário

inexperiente possa acabar deixando de observar algumas peculiaridades associados ao sistema que está modelando.

O modelo SWAT é sensível a centenas de variáveis de entrada que estão relacionadas à vegetação, ao manejo da terra, ao solo, ao clima, ao aquífero, aos canais e ao reservatório (ARNOLD et al., 2000); que podem ser avaliadas através do *software* SWAT-CUP. O SWAT-CUP é uma ferramenta auxiliar na calibração, na validação e na análise de sensibilidades dos projetos gerados no SWAT (ABBASPOUR, 2015).

A análise de sensibilidade, calibração e análise de incertezas compõem aspecto essencial da aplicação de modelos como o SWAT (GASSMAN et al., 2007).

O SWAT-CUP realiza a análise de sensibilidade simultaneamente à calibração. Para isso, o usuário define uma função objetivo, que é então aplicada a cada parâmetro, em cada simulação. Quanto maiores as variações no valor dessa função em decorrência das alterações nos valores do parâmetro, mais sensível é esse parâmetro (ABBASPOUR, 2015). Van Griensven et al. (2006) sugerem uma classificação dos parâmetros, conforme sua posição na análise de sensibilidade (Tabela 4).

Tabela 4 - Influência da posição do parâmetro na Análise de Sensibilidade no processo de Calibração

Categoria	Posição do parâmetro
Muito importante	1
Importante	2 a 6
Ligeiramente importante	7 a 19
Sem importância	20 a 28

Fonte: Van Griensven et al. (2006)

No processo de calibração, busca-se estimar os parâmetros de entrada do modelo, comparando-se as saídas calculadas— para um determinado conjunto de condições assumidas— aos valores observados, para as mesmas condições (MORIASI et al., 2007, ARNOLD et al., 2012b). Esse processo assegura a representatividade da resposta do modelo na etapa em que ele for utilizado para previsões. A calibração pode ser realizada de forma manual ou automática.

A forma manual é realizada por tentativa e erro, sendo o modelo executado para cada tentativa de ajuste, verificando-se as mudanças nos valores de saída. Os dados calculados são comparados aos dados observados por meio de gráficos e, muitas vezes, por índices de desempenho (coeficiente de determinação, Nash-Sutcliffe, erro absoluto, raiz quadrada do erro quadrático médio, desvio percentual, etc.). O processo é repetido, alterando-se os parâmetros

dentro de uma faixa aceitável, até que um ajuste admissível seja alcançado; ou seja, até que os valores simulados estejam próximos aos valores observados (ARNOLD et al., 2012b).

Esse processo é bastante subjetivo e há uma dificuldade em estipular quando ele deve ser terminado. Entretanto, esse tipo de calibração pode ser interessante para que se estabeleçam os valores iniciais dos parâmetros, que devem ser utilizados no método de calibração automática (por exemplo: para utilização no *software* SWAT-CUP).

No entanto, em modelos complexos como o SWAT, com inúmeros parâmetros a serem definidos, pode ser complicada a execução de um processo de calibração manual (GREEN e VAN GRIENSVEN, 2008); de forma que, a realização de procedimentos de calibração automática tem sido desenvolvida com grande sucesso (GREEN e VAN GRIENSVEN, 2008; VAN GRIENSVEN e BAUWENS, 2003; VAN GRIENSVEN et al., 2006).

A forma automática de execução do processo de calibração baseia-se em técnicas computacionais de otimização, para determinar os valores dos parâmetros do modelo, considerando o emprego de funções objetivo e dos valores observados. A finalidade desse tipo de calibração é descobrir os valores dos parâmetros que otimizam (minimizem ou maximizem) o valor numérico de uma função objetivo pré-determinada (TUCCI, 2005). Esse procedimento é realizado para obter os parâmetros ótimos, de maneira a reduzir a incerteza da previsão (GREEN e VAN GRIENSVEN, 2008; ARNOLD et al., 2012b), podendo ser executado através do *software* SWAT-CUP; que também possibilita a execução da calibração associada a uma análise de sensibilidade dos parâmetros.

Na alteração dos parâmetros fornece-se sua faixa de variação, através da definição do “Limite inferior” e “Limite superior”; de modo a evitar a geração de resultados fictícios, inalcançáveis na situação real. Essa variação pode ser realizada de três formas (ABBASPOUR, 2015):

- Substituição direta: o programa faz alterações do valor diretamente;
- Por adição: um valor constante, definido pelo usuário, é adicionado ao valor inicial do parâmetro;
- Por multiplicação: a alteração dos valores é estabelecida variando-se o valor inicial por porcentagem, para mais ou para menos. Os parâmetros que possuem referência espacial— aqueles que podem apresentar variação dos valores em relação a sua localização na bacia—, devem sempre ser alterados pelo método da “multiplicação”, para que seja mantida sua referência espacial. Do contrário, corre-se o risco de homogeneizar os valores desse parâmetro para toda a área,

prejudicando a resposta final gerada pelo modelo SWAT no processo de simulação.

O SWAT-CUP fornece uma lista completa dos parâmetros do modelo SWAT para que o usuário escolha quais deles quer alterar no processo de calibração do modelo. Desse modo, para que a calibração não se torne excessivamente demorada, é preciso definir com quais parâmetros se deseja trabalhar.

A Tabela 5 e a Tabela 6 trazem os parâmetros do modelo SWAT mais sensíveis, diagnosticados em diversos estudos realizados em diferentes regiões do Brasil. Tais parâmetros têm sido variados durante a etapa de calibração dos processos hidrossedimentológicos nas bacias hidrográficas.

A seguir apresenta-se uma breve descrição do significado dos principais parâmetros comumente utilizados na calibração do modelo SWAT para os processos hidrossedimentológicos (NEITSCH et al., 2002, 2005, 2010, 2011):

- *ESCO*: é o fator de compensação da evaporação do solo, ajustando a distribuição da evaporação do solo nas diversas camadas, conforme o efeito da ação de capilaridade. Quando o valor desse parâmetro é reduzido, isso significa que o modelo pode extrair mais água através da evaporação das camadas inferiores do solo;
- *CN2*: é o valor inicial da Curva Número do escoamento superficial para a condição de umidade II (solo úmido);
- *CANMX*: é a máxima quantidade de água da chuva interceptada pela vegetação plenamente desenvolvida, disponível para evaporar sem atingir o solo;
- *HRU_SLP*: é definido como uma média da declividade de cada HRU, influenciando fortemente o escoamento superficial e a infiltração;
- *SOL_AWC*: controla a quantidade de água disponível na camada de solo, correspondendo ao volume total de água disponível para as plantas quando o solo está na condição de capacidade de campo. A capacidade de água disponível é estimada através da determinação da quantidade de água liberada entre a condição de capacidade de campo e o ponto de murcha permanente;
- *SOL_K*: condutividade hidráulica saturada. Relaciona o fluxo de água no solo ao gradiente hidráulico e se refere à facilidade do movimento da água através do solo;
- *ALPHA_BF*: é a constante de recessão do escoamento de base;

Tabela 5 - Parâmetros detectados como de maior sensibilidade, considerando estudos que utilizaram o modelo SWAT em diferentes regiões do Brasil para estimativa dos processos hidrológicos

Parâmetros mais sensíveis	Autores	Região
ESCO, ALPHA_BF, SOL_Z, GWQMN, GW_DELAY, SOL_AWC, REVAPMN, SURLAG, GW_REVAP, CN2	Durães (2010)	Sudeste
ESCO, SOL_AWC, SLOPE, CN2, SLSUBSN	Rocha et al. (2010)	
ALPHA_BF, CH_K2, CN2, SURLAG, SOL_K, CH_N2, GWQMN, ESCO, SLOPE, GW_DELAY, BLAI, CANMX, SOL_AWC, SOL_Z, GW_REVAP, BIOMIX, SOL_ALB, REVAPMN, EPCO, SLSUBSN	Pinto (2011)	
CN2, ALPHA_BF, GW_DELAY, ESCO, CH_N2, CH_K2, ALPHA_BNK, SOL_AWC, SOL_K, SOL_BD	Kuwajima (2012)	
ESCO, ALPHA_BF, EPCO, SOL_Z, CANMX, CH_K2, SOL_AWC, SOL_K, CN2	Lelis et al. (2012)	
CN2, ALPHA_BF, RCHRG_DP, ESCO, SOL_Z, SOL_AWC, SOL_K	Andrade, Mello e Beskow (2013)	
ESCO, GWQMN, CN2, SOL_AWC, REVAPMN, SOL_Z, BLAI, CANMX, GW_REVAP, SOL_K, SLOPE, CH_K2, EPCO, ALPHA_BF, SOL_ALB, GW_DELAY, CH_N2, SURLAG, SLSUBSN	Pinto (2014)	
BLAI, ESCO, SOL_AWC, CANMX, CN2, SOL_K, GWQMN, SLOPE, CH_K2, SOL_Z, GW_REVAP, ALPHA_BF, REVAPMN, CH_N2, EPCO, GW_DELAY, BIOMIX, SOL_ALB, SURLAG, USLE_P e SLSUBSN	Brito (2015)	Sul
ESCO, CN2, CANMX, HRU_SLP, SOL_AWC, SOL_K, ALPHA_BF, GW_DELAY, RCHRG_DP, CH_K2, CH_N2	Gibertoni et al. (2009)*	
ALPHA_BF, CN2, ESCO, CANMX, SOL_AWC, REVAPMN, GWQMN, SOL_Z, BLAI, CH_K2, SURLAG, CH_N2, GW_DELAY, GW_REVAP. Mais influentes calibração manual: ALPHA_BF, CN2, ESCO, SURLAG, GW_DELAY	Lino (2009)	
CANMX, CN2, ALPHA_BF, ESCO, SLOPE, SOL_K, BLAI, SOL_Z, SOL_AWC, GWQMN, CH_K2, SURLAG, EPCO, CH_N2, SOL_ALB, GW_DELAY, (baixa sensibilidade: GW_REVAP, SLSUBSN, REVAPMN, BIOMIX)	Lubitz (2009)	
ALPHA_BF, ESCO, SOL_Z, CANMX, SOL_AWC, REVAPMN, GWQMN, BLAI, SLOPE, SOL_K, CH_K2, GW_REVAP, CN2, GW_DELAY, EPCO, CH_N2, BIOMIX, SURLAG, SOL_ALB, SLSUBSN	Paim e Menezes (2009)	
CN2, ESCO, ALPHA_BF, CH_K2, BLAI, GWQMN, SOL_K, CANMX, SLOPE, SOL_AWC, SOL_Z, CH_N2, SURLAG, EPCO, REVAPMN, GW_DELAY, GW_REVAP, SOL_ALB, SLSUBSN, USLE_P	Bonumá et al. (2010)	
CN2, ESCO, ALPHA_BF, CH_K2, BLAI, GWQMN, SOL_K, CANMX, SLOPE, SOL_AWC, SOL_Z, CH_N2, SURLAG, EPCO, REVAPMN, GW_DELAY, GW_REVAP, SOL_ALB, SLSUBSN, BIOMIX	Bonumá (2011)	
ESCO, ALPHA_BF, CH_K2, CANMX, SOL_AWC, SOL_K, CN2, SLOPE, BLAI, GWQMN	Bonumá et al. (2011)	
ESCO, ALPHA_BF, GW_DELAY, GWQMN, SFTMP e SURLAG, SOL_AWC, GW_REVAP	Conceição et al. (2012)	
ESCO, ALPHA_BF, SOL_Z, CANMX, SOL_AWC, CN2, SLOPE, BLAI, GWQMN, REVAPMN	Garbossa et al. (2011)	
ESCO, ALPHA_BF, GW_DELAY, SURLAG, CN2	Lino et al. (2009)	
ALPHA_BF, ESCO, CANMX, BLAI, GWQMN, REVAPMN, GW_REVAP, SOL_Z, SOL_AWC, CH_K2, SOL_K, SURLAG, GW_DELAY, BIOMIX	Malutta (2012)	
CN2, ESCO, ALPHA_BF, CH_K2, BLAI, GWQMN, SOL_K, CANMX, SLOPE, SOL_AWC, SOL_Z, CH_N2, SURLAG, EPCO, REVAPMN, GW_DELAY, GW_REVAP, SOL_ALB, SLSUBSN, BIOMIX	Bonomá et al. (2013)	
mais sensíveis: CANMX, SOL_K, CN2 e SLOPE (apresenta sensibilidade: CANMX, SLOPE, SOL_K, SLSUBSN, CN2, SOL_AWC, ESCO, CANMX)	Lubitz, Pinheiro e Kaufman (2013)	
SURLAG, CH_N1, CN2, SLSOIL, GW_REVAP, RCHRG_DP, CH_K1, CH_K2, GWQMN, CH_N2, GW_DELAY, SOL_AWC, CANMX, ESCO, LAT_TTIME	Brighenti (2015)	
ALPHA_BF, CN, ESCO, CANMX, SOL_AWC, REVAPMN, GWQMN, SOL_Z, BLAI, CH_K2, SURLAG, CH_N2, GW_DELAY, GW_REVAP	Zanin (2015)	
ESCO, CH_N1, GWQMN, LAT_TTIME, CN2, CH_K1, CANMX, CH_K2, SOL_AWC, GW_REVAP, GW_DELAY, SLSOIL, CH_N2, SURLAG	Brighenti, Bonumá e Chaffe (2016)	
SURLAG, GW_REVAP, CN2, RCHRGDP, SOL_Z	Samento (2010)	Centro-Oeste
CN2, SURLAG, RCHRG_DP, GWQMN, SOL_Z, GW_REVAP, ESCO, GW_DELAY, SOL_AWC, CH_K2, ALPHA_BF, CANMX, SLSUBSN, SLOPE, BIOMIX, SOL_K, EPCO, CH_N, REVAPMN, SOL_ALB	Silva (2010)	
CN2, ALPHA_BF, CH_K2, ESCO, GW_DELAY, CH_N2, GWQMN, CANMX, SURLAG	Strauch et al. (2011)	
ESCO, ALPHA_BF, GW_DELAY, SOL_Z, CH_K2, BLAI, SOL_AWC, CN2, SOL_K, GWQMN, SLOPE, EPCO, GW_REVAP, CANMX, CH_N2, SURLAG, SLSUBSN, BIOMIX, SOL_ALB	Ferrigo, Minotti e Koile (2011)	
ESCO, ALPHA_BF, GWQMN, SURLAG, GW_REVAP, CN2, CH_K2, RCHRG_DP, CH_N2, REVAPMN	Salles (2012)	
SURLAG, ALPHA_BF, CN2, GWQMN, SOL_K, CH_K2, SLOPE, SLSUBSN, BLAI, SOL_ALB	Castro (2013)	
ALPHA_BF, CN2, GW_DELAY, GWQMN, GW_REVAP, ESCO, SLSUBSN	Ferrigo et al. (2014)	
ESCO, SOL_AWC, GWQMN, REVAPMN, SOL_Z, GW_REVAP, ALPHA_BF, BLAI, CANMX, CN2, CH_K2, EPCO, CH_N1, SLOPE, SOL_K (classificação média das simulações)	Veiga (2014)	Nordeste
SOL_AWC, CN2, SOL_K, GW_REVAP, SLSUBSN, CANMX, GW_DELAY, GW_REVAP, SOL_Z, ALPHA_BF, CH_K2	Santos et al. (2014)	
SURLAG, ALPHA_BF, CH_K2, ESCO, SOL_AWC, CN2, SLOPE, GW_REVAP, SLSUBSN	Silva e Medeiros (2014)	
GWQMN, CN2, GW_DELAY, LAT_TTIME, REVAPMN, SLSUBSN, OV_N, ALPHA_BF, GW_REVAP	Silva (2014)	
ALPHA_BF e BIOMIX, SOL_K, CANMX, CH_N2, SLSUBSN, SOL_ALB, REVAPMN, EPCO, ESCO, RCHRG_DP, CH_K2, SURLAG	Dantas et al. (2015)	
CN2, ESCO, ALPHA_BF, REVAPMN, DEEPST, GW_REVAP, GW_DELAY, GWQMN e SHALLST	Fernandes (2015)	

* Não descrita ordem de sensibilidade dos parâmetros

Fonte: Adaptado de Castro (2013)

Tabela 6 - Parâmetros detectados como de maior sensibilidade, considerando estudos que utilizaram o modelo SWAT em diferentes regiões do Brasil para estimativa dos processos sedimentológicos

Parâmetros mais sensíveis	Autores	Região
USLE_C, SLSUBBSN, USLE_P, SLOPE	Adriolo et al. (2008)	Sul
USLE_P, USLE_C, SPCON	Baltolski (2008)	
SLOPE, SOL_Z, densidade volumétrica do solo, SOL_AWC, SOL_K; USLE_P, USLE_C	Lenhart et al. (2002)	
LAT_SED, RSDIN, CN2, CH_COV, CH_EROD (não investigados USLE_P e USLE_C - bacia não agrícola)	Gibertoni et al. (2009)*	
USLE_P, CN2, SLOPE, SLSUBBSN, CANMX, ESCO, SURLAG, EPCO, SOL_Z, SOL_AWC, BLAI, USLE_C, CH_N2, SOL_K, BIOMIX, ALPHA_BF, CH_K2, SPCON, SPEXP, SOL_ALB, GW_DELAY, GWQMN	Bonumá et al. (2010)	
ADJ_PKR, LAT_SED, SPCON, SPEXP, PRF, CH_EROD, CH_COV (USLE_K e USLE_P não foram alterados, pois foram calculados e não calibrados)	Malutta (2012)*	
SPCON, PRF, LAT_SED. Parâmetros de pouca ou nenhuma influência: ADJ_PKR, USLE_C, CH_EROD e CH_COV,	Lubtz, Pinheiro e Kaufman (2013)	Centro Oeste
SLSUBBSN, ADJ_PKR, USLE_C, PRF, CH_COV2, SPEXP, CH_COV1, SPCON, LAT_SED, USLE_K, USLE_P	Carvalho (2014)	
USLE_P, SPCON, SPEXP, USLE_C, CH_COV e CH_EROD (=sensibilidade)	Veiga (2014)	
ESCO, SURLAG, SOL_AWC, ALPHA_BF, CN2, RCHRG_DP, CH_K2, GWQMN, GW_REVAP	Medeiros e Silva (2014)	Nordeste
SURLAG, ALPHA_BF, CH_K2, ESCO, SOL_AWC, CN2, SLOPE, GW_REVAP, SLSUBBSN	Silva e Medeiros (2014)	
SLSOIL, EPCO, ESCO, USLE_K, SOL_AWC, SOL_ALB	Silva (2014)	Sudeste
SPCON, SPEXP, USLE_P	Pinto (2011)	

* Não descrita ordem de sensibilidade dos parâmetros

Fonte: autora

- *GW_DELAY*: regula o tempo de recarga do aquífero, representando o tempo necessário para a água atravessar a camada imediatamente abaixo da zona de raízes até chegar ao aquífero superficial;
- *RCHRG_DP*: regula a percolação da zona de raízes para o aquífero profundo;
- *CH_K2* e *CH_N2*: regulam o escoamento dentro da calha do rio principal. O parâmetro *CH_K2* (condutividade efetiva do canal principal) relaciona o escoamento dentro da calha com o aquífero subterrâneo, categorizando o canal como fornecedor ou receptor de água deste sistema. O *CH_N2* corresponde ao coeficiente de rugosidade de Manning do canal principal;
- *LAT_SED*: reflete a concentração de sedimentos no escoamento subsuperficial, que contribui para o canal principal;
- *RSDIN*: representa o material residual depositado nos primeiros 10 mm do solo;
- *CH_COV*: fator de cobertura vegetal do canal. Representa o raio da degradação do canal, com sua cobertura vegetal, em relação ao canal destituído desta cobertura. A vegetação do canal afeta a degradação por reduzir a velocidade do fluxo e evitar o contato intenso com o material do leito;
- *CH_EROD*: é conceitualmente similar ao fator de erodibilidade do solo usado na equação USLE, sendo uma função das propriedades do material do leito e margens. Representa, portanto, o fator de erodibilidade do canal;

- *REVAPMN*: profundidade limite de água no aquífero raso para ocorrer o revap (percolação);
- *ADJ_PKR*: fator de ajuste da taxa de pico para o aporte de sedimentos na sub-bacia;
- *FILTERW*: largura da borda de campo de filtros em tira;
- *USLE_K*: fator K de erodibilidade do solo da USLE;
- *USLE_P*: fator P de práticas de suporte da USLE;
- *USLE_C*: valor mínimo do fator C de cobertura vegetal da USLE;
- *SPCON*: parâmetro linear para o cálculo da quantidade máxima de sedimentos que pode estar reentrando durante o aporte de sedimentos no canal;
- *SPEXP*: parâmetro exponencial para o cálculo da reentrada de sedimentos no aporte ao canal;
- *PRF*: fator de ajuste da taxa de pico para o aporte de sedimentos no canal principal;
- *SLOPE*: rampa média adotada para todas as HRU's em uma sub-bacia;
- *SLSUBBSN*: comprimento de rampa médio para a sub-bacia, adotado como sendo o mesmo valor utilizado para o comprimento de rampa do escoamento lateral;
- *SURLAG*: coeficiente de atraso (*lag*) do escoamento superficial;
- *GWQMN*: profundidade do aquífero para escoamento de base;
- *GW_REVAP*: coeficiente que controla o fluxo de água da zona saturada para a não saturada;
- *BIOMIX*: eficiência biológica;
- *BLAI*: máximo de área foliar potencial da cultura;
- *SOL_Z*: profundidade do solo;
- *SOL_ALB*: albedo do solo úmido;
- *SOL_K*: condutividade hidráulica saturada;
- *EPCO*: fator de crescimento da cultura;
- *LAT_TTIME*: tempo do escoamento lateral;
- *OV_N*: coeficiente de rugosidade de Manning para escoamento na superfície;
- *SOL_BD*: densidade do solo úmido;
- *CH_N1*: coeficiente de rugosidade de Manning dos canais tributários;
- *CH_K1*: Condutividade efetiva dos canais tributários;
- *ALPHA_BNK*: é a constante de recessão do escoamento de base para as margens do canal;

- *SFTMP*: temperatura da precipitação;
- *SHALLST*: profundidade inicial da água no aquífero raso;
- *DEEPST*: profundidade inicial da água no aquífero profundo;
- *SLSOIL*: comprimento da declividade para o escoamento subsuperficial.

Neitsch et al. (2005) sugere os parâmetros CN2, ALPHA_BF, ESCO e SURLAG sejam os primeiros parâmetros a serem alterados para adequação do ajuste entre as vazões observadas e simuladas pelo modelo.

Arnold et al. (2012b) indicaram as variáveis mais utilizadas no processo de calibração, a partir de resultados de 64 estudos, definindo os parâmetros CN2, SOL_AWC, ESCO, SURLAG, EPCO e OV_N como os comumente modificados para determinação do escoamento superficial e; os parâmetros ALPHA_BF, GW_DELAY, GW_REVAP, RCHRG_DP, GWQMN e REVAPMN, como os de maior influência sobre o fluxo de base.

Lubitz (2009), ao avaliar a aplicabilidade do modelo SWAT à bacia do Ribeirão Concórdia (Lontras, SC), observou que os parâmetros mais sensíveis à evapotranspiração eram CANMX, SLOPE e SOL_K; ao aumento da percolação eram SOL_K, SLOPE e SLSUBBSN; à diminuição do escoamento superficial eram CN2, SOL_AWC e ESCO; para o aumento do escoamento de base eram SLOPE, SOL_K e SLSUBBSN e; por fim, para alteração do escoamento no canal, os parâmetros mais importantes eram CANMX, SOL_K e SLOPE.

Ferrigo (2014) destaca ALPHA_BF, CN2, ESCO, SOL_AWC, GW_REVAP, GW_DELAY, SURLAG, CANMX, SOL_K, GWQMN, SHALLST, RCHRG_DP, SLOPE, SOL_Z, CH_K2 e SLSUBBSN entre os parâmetros mais sensíveis identificados em análises de sensibilidade do modelo SWAT no Brasil (30 estudos).

Para a produção de sedimentos no canal, os parâmetros mais sensíveis, identificados por Arnold et al. (2012b) na avaliação de diferentes estudos, foram: PRF, APM (ou ADJ_PKR no SWAT2012), SPEXP, SPCON, CH_EROD e CH_COV. Por outro lado, para a produção de sedimentos na paisagem, os parâmetros de maior destaque, reportados pelos autores, foram: USLE_P, USLE_C, USLE_K, LAT_SED, SLSOIL e SLOPE.

Na Tabela 7 são descritos os efeitos de alguns parâmetros, comumente calibrados no modelo SWAT, sobre (1) redução do volume de escoamento total; (2) aumento do escoamento de base e recessão do hidrograma e; (3) retardo do escoamento.

Quando a vazão líquida simulada se encontra muito elevada, sua diminuição pode ser realizada pelo aumento dos valores dos parâmetros GWQMN e GW_REVAP, bem como pela diminuição do REVAPMN. Por outro lado, a correção de possíveis deslocamentos nos

hidrogramas de vazão observada e simulada, pode ser efetuada pela alteração do fator ALPHA_BF para o máximo permitido pelo modelo, pois esse parâmetro tem relação direta com as recessões do hidrograma.

Tabela 7 - Efeitos de alguns parâmetros sobre (1) redução do volume de escoamento total, (2) aumento do escoamento de base e recessão do hidrograma, e (3) retardo do escoamento

Parâmetro	Efeito		
	1	2	3
ALPHA_BF		+	
CANMX	+		
CN2	-	-	
ESCO	-		
GWQMN		-	
GW_REVAP		-	
LAT_TTIME			+
RCHRG_DP	+	-	
REVAPMN		+	
SLOPE	-	-	
SLSUBBASIN	+	+	
SOL_AWC	+		
SOL_K	-	-	
SURLAG			-

Fonte: Adaptado de Lubtz, Pinheiro e Kaufmam (2013)

O parâmetro GW_REVAP, ao controlar o fluxo de água da zona saturada (aquífero) para a zona não saturada do solo, influencia a dinâmica da água subterrânea na bacia e por consequência, também tem relação direta com as vazões mínimas (ARNOLD et al., 2012b).

O parâmetro GW_DELAY relaciona-se com o escoamento de base e influencia a dinâmica da água, apresentando alta sensibilidade na calibração de vazões mínimas (NEITSCH et al., 2005, 2010). A quantidade de água disponível nas camadas de solo para a extração das plantas é controlada pelo parâmetro SOL_AWC, que está relacionado aos processos de percolação, de evaporação e à dinâmica da água subterrânea na bacia.

A condutividade hidráulica, por sua vez, influencia os processos de percolação, fluxo lateral e dinâmica da água subterrânea (NEITSCH et al., 2005, 2010). A condutividade hidráulica saturada (SOL_K) é uma característica física do solo, possível de ser medida em campo, embora seja comum sua estimativa no processo de calibração, devido à grande heterogeneidade espacial desse parâmetro (DEPINÉ, 2014).

No ajuste da produção e sedimentos na bacia podem-se alterar os diferentes fatores que influenciam esses processos erosivos, de transporte e de deposição de sedimentos, conforme sugerido na Tabela 8. Alguns fatores relacionados aos processos hidrológicos também poderão afetar a geração de sedimentos, tais como os relacionados à vazão de pico.

Tabela 8 - Listagem dos parâmetros que podem ser alterados para ajustes da produção de sedimentos

Aumento da produção de sedimentos na fase terrestre	Aumento da degradação (transporte ao longo dos canais)	Diminuição da deposição
ADJ_PKR (+); LAT_SED (+); FILTERW (-); USLE_K (+); USLE_P (+); USLE_C (+)	SPCON (+); PRF (+); SPEXP (+); CH_EROD (+); CH_COV (+)	SPCON (+); PRF (+); SPEXP (+)

Onde: (+) indica que deve ser aumentado o valor do parâmetro para obter o efeito citado e; (-) indica que o parâmetro deve ser reduzido para obter o efeito citado

Fonte Adaptado de Lubitz (2009)

O SWAT-CUP permite a escolha de cinco diferentes procedimentos de calibração, que possibilitam a realização das análises de sensibilidade e incerteza, calibração, e verificação do modelo. São eles: i) Probabilidade Generalizada da Estimativa de Incerteza (*Generalized Likelihood Uncertainty Estimation - GLUE*), ii) Solução de Parâmetros (*Parameter Solution - ParaSol*), iii) Sequencial de Montagem das Incertezas (*Sequential Uncertainty Fitting algorithm - SUFI-2*), iv) Métodos de Monte Carlo via Cadeias de Markov (*Markov chain Monte Carlo - MCMC*), e v) Método do enxame de partículas (*Particle Swarm Optimization - PSO*) (ABBASPOUR, 2015).

O SUFI-2 emprega o método do hipercubo latino para definição dos parâmetros, sendo o processo iniciado com uma faixa de valores determinada pelo usuário. O valor de cada parâmetro selecionado é substituído dentro do projeto do modelo SWAT, realizando-se esse processo quantas vezes o usuário achar necessário (ROUHOLAHNEJAD et al., 2012). Abbaspour et al. (2007) sugere que o número de simulações realizada seja elevado (entre 500 a 1000), sendo 2001 simulações o valor máximo permitido dentro da plataforma. Esse procedimento considera na análise de incerteza todas as suas fontes, entre elas a incerteza em variáveis de entrada, no conceitual do modelo e as incertezas nos parâmetros e nos dados medidos.

O grau para o qual todas as incertezas são contabilizadas é quantificado por uma medida referida como o fator-p (*p-factor*), que é a porcentagem dos dados medidos delimitadas pela incerteza de predição de 95% (95PPU). O 95PPU é calculado entre 2,5% e 97,5% da distribuição cumulativa da variável de saída, obtida pelo hipercubo latino. Outra medida que busca quantificar a eficácia de uma análise de calibração e incerteza é o fator-r (*r-factor*), que é a espessura média da banda 95PPU dividida pelo desvio padrão dos dados medidos (ABBASPOUR, 2015). O fator-p varia entre 0 e 100%, enquanto o fator-r entre 0 e infinito. Um fator-p igual a 1 e fator-r igual a 0, são simulações que correspondem exatamente aos dados observados (BRIGHENTI, 2015).

O fator-p é a porcentagem de observações enquadradas pelo 95PPU, dada pela equação 14:

$$\overline{dx} = \frac{1}{k} \cdot \sum_{l=i}^k (X_u - X_L) \cdot l \quad (14)$$

Onde, \overline{dx} é a distância entre os limites superior e inferior de 95PPU; k é o número de pontos de dados observados; X_u é o percentil correspondente a 97,5% da distribuição cumulativa de cada ponto simulado; X_L percentil correspondente a 2,5% da distribuição cumulativa de cada ponto simulado.

A fim de obter uma melhor medida para \overline{dx} , o fator-r é calculado pela equação 15:

$$fator-r = \frac{\overline{dx}}{\hat{\sigma}_x} \quad (15)$$

Onde: $\hat{\sigma}_x$ é o desvio padrão da variável medida x .

O processo de calibração dentro da plataforma SUFI-2 consiste em (BRIGHENTI, 2015):

a) *Passo 1*: definição dos limites máximos e mínimos para cada um dos parâmetros que será calibrado. Assume-se que todos os parâmetros são distribuídos uniformemente dentro da região delimitada pelos valores mínimos e máximos, por meio do método hipercubo latino;

b) *Passo 2*: definição da função objetivo, que representa a condição para a decisão dos parâmetros finais na simulação;

c) *Passo 3*: determinação da sensibilidade dos parâmetros em relação a cada simulação através do sistema de regressão linear múltipla, que faz a regressão dos valores gerados pelo hipercubo latino em relação aos da função objetivo. Em seguida um teste é realizado para ranquear a significância de cada parâmetro. As medidas de sensibilidade são estimativas das alterações resultantes das variações dos parâmetros.

Por fim, a sensibilidade dos parâmetros pode ser realizada de duas maneiras: i) análise de sensibilidade global (*global sensibility*) e; ii) um fator por vez (*one-at-a-time*). A análise de sensibilidade global é calculada através do sistema de regressão linear múltipla, a qual faz a regressão dos valores gerados pelo hipercubo latino em relação aos da função objetivo. A *one-at-a-time* mostra a sensibilidade de uma variável, se todos os outros parâmetros permanecem constantes. O valor da sensibilidade de cada parâmetro pode ser dado pelo *p-Value*, onde quanto mais próximo de zero, mais sensível é o parâmetro.

Contudo, é interessante que antes de se efetuar a calibração automática seja realizada uma pré-calibração manual do modelo, empregando-se a calibração automática para melhorar a precisão dos parâmetros pré-definidos na calibração manual.

É preciso destacar ainda, que os valores calibrados para os parâmetros de entrada são válidos unicamente para a situação em que foram gerados (condições analisadas no modelo e para as características do local estudado). Desse modo, as aplicações em locais distintos do analisado e as comparações entre diferentes estudos precisam ser criteriosamente avaliadas.

Os índices geralmente empregados para avaliação do desempenho do modelo SWAT, em simulações hidrossedimentológicas e de qualidade da água, são descritos a seguir e apresentados nas equações 16, 17 e 18 (MORIASI et al., 2007).

- Nash-Sutcliffe (NS): é uma estatística normalizada que determina a magnitude relativa da variância residual em comparação com a variância dos dados medidos (NASH e SUTCLIFFE, 1970). O NS varia entre $-\infty$ e 1,0 (inclusive), com NS=1 representando o valor ideal. Os valores compreendidos entre 0,0 e 1,0 são vistos como níveis aceitáveis de desempenho, já os valores negativos sugerem que o valor médio observado é melhor preditor do que o valor simulado, indicando desempenho inaceitável do modelo.

$$NS = 1 - \left[\frac{\sum_{i=1}^n (Y_i^{obs} - Y_i^{sim})^2}{\sum_{i=1}^n (Y_i^{obs} - Y_{med}^{obs})^2} \right] \quad (16)$$

Onde: Y_i^{obs} é a i-ésima observação da variável avaliada; Y_i^{sim} é a i-ésima simulação da variável avaliada; Y_{med}^{obs} é a média do conjunto de valores observados, e n é o número total de dados observados.

- Porcentagem bias (PBIAS): informa a tendência média dos dados, ou seja, se eles são maiores ou menores do que os observados. PBIAS=0 representa o valor ideal e quanto mais baixo seu valor absoluto, mais adequada é a simulação do modelo. Valores positivos expressam subestimativa do modelo e os negativos indicam a superestimativa.

$$PBIAS = \left[\frac{\sum_{i=1}^n (Y_i^{obs} - Y_i^{sim}) * 100}{\sum_{i=1}^n (Y_i^{obs})} \right] \quad (17)$$

- Coeficiente de desvio padrão das observações (RSR): é a razão entre a raiz quadrada do erro quadrático médio (RMSE) e o desvio padrão dos dados observados (STDEV^{obs}). Ele representa a padronização do RMSE, incorporando os benefícios das estatísticas de índice de

erro, e inclui um fator de escalonamento/normalização, de modo que os valores estatísticos resultantes podem ser aplicados a vários constituintes. O RSR varia entre o valor ideal (RSR=0)— que indica uma variação residual ou RMSE zero, sendo o modelo classificado como perfeito— até um valor positivo grande. Quanto menor for o RSR, melhor será o desempenho modelo.

$$RSR = \frac{RMSE}{STDEV^{obs}} = \frac{\sqrt{\sum_{i=1}^n (Y_i^{obs} - Y_i^{sim})^2}}{\sqrt{\sum_{i=1}^n (Y_i^{obs} - Y_{med}^{obs})^2}} \quad (18)$$

Outro índice que costuma ser utilizado em simulações hidrossedimentológicas é o Coeficiente de Determinação (R^2), apresentado na equação 19. Esse índice varia entre 0 e 1, com $R^2=1$ representando o desempenho ótimo do modelo. Quanto menor o valor desse coeficiente, menor é a variação do erro.

$$R^2 = \frac{\left(\sum_{i=1}^n (Y_i^{sim} - Y_{med}^{obs})(Y_i^{sim} - Y_{med}^{sim}) \right)^2}{\sum_{i=1}^n (Y_i^{sim} - Y_{med}^{obs})^2 \sum_{i=1}^n (Y_i^{sim} - Y_{med}^{sim})^2} \quad (19)$$

Onde: Y_{med}^{sim} é a média aritmética dos dados simulados pelo modelo.

Na Tabela 9 são apresentados os critérios de classificação do desempenho de modelos, proposto por Moriasi et al. (2007), considerando 4 classes de desempenho para os três coeficientes estatísticos mais utilizados em modelagens hidrológicas e de qualidade da água.

Tabela 9 - Classificação do desempenho de um modelo para os principais índices estatísticos utilizados

Desempenho do modelo	Índices de desempenho			
	RSR	NS	PBIAS	
			ES e Q	Sedimentos
Muito Bom	$0,00 \leq RSR \leq 0,50$	$0,75 < NS \leq 1,00$	$PBIAS < \pm 10$	$PBIAS < \pm 15$
Bom	$0,50 < RSR \leq 0,60$	$0,65 < NS \leq 0,75$	$\pm 10 \leq PBIAS < \pm 15$	$\pm 15 \leq PBIAS < \pm 30$
Satisfatório	$0,6 < RSR \leq 0,70$	$0,50 < NS \leq 0,65$	$\pm 15 \leq PBIAS < \pm 25$	$\pm 30 \leq PBIAS < \pm 55$
Insatisfatório	$RSR > 0,70$	$NS \leq 0,5$	$PBIAS \geq \pm 25$	$PBIAS \geq \pm 55$

Os valores descritos para os índices RSR e NS são válidos para vazão (Q), escoamento superficial (ES) e sedimentos

Fonte: Moriasi et al. (2007)

Os procedimentos de calibração do modelo SWAT devem adotar a seguinte ordem: 1º) processos hidrológicos e 2º) aporte de sedimentos, já que o sedimento é transportado com o escoamento superficial. Findado o processo de calibração passa-se então à verificação dos

parâmetros calibrados. Nessa etapa utiliza-se uma série de dados ainda não empregada nas etapas anteriores, a fim de se testar o desempenho do modelo após a sua calibração.

O processo de verificação é executado de forma análoga aos procedimentos de calibração, realizando-se a comparação entre os valores calculados e os observados (para uma série não utilizada na calibração), e empregando-se a avaliação de uma dada função-objetivo.

Os índices para classificação do desempenho do modelo também seguem as classes sugeridas por Moriasi et al. (2007). Bons resultados de verificação apoiam o uso do modelo para prever cenários futuros de clima e uso do solo, e variações das práticas de gestão e gerenciamento de uma bacia hidrográfica.

Há que considerar ainda, que no início da simulação de um modelo ocorrem incertezas devido ao desconhecimento das condições iniciais, principalmente da umidade do solo, tornando necessária a utilização de um período de aquecimento do modelo (“*warm-up*”). Isso possibilita que, ao se iniciar a simulação, as variáveis estejam livres da influência das condições iniciais. Quanto menor for o período de simulação maior importância terá o tempo necessário para alcançar o equilíbrio dos valores iniciais (ARNOLD et al., 2012a).

Para simulações com uma série de 30 anos ou mais é opcional a utilização de um período de aquecimento, entretanto quando essa série é menor (cinco anos ou menos) é indicado o uso desse período de equilíbrio das condições iniciais. Nesse caso, um período de um ano geralmente é suficiente para adequar a funcionalidade do ciclo hidrológico, assegurando as características de equilíbrio necessárias (ARNOLD et al., 2012a).

2.4.3.2 O SWAT e a modelagem hidrossedimentológica: alguns estudos brasileiros e seus apontamentos

A aplicação do modelo SWAT tem passado por um processo de expansão no Brasil, com mais de 100 estudos publicados em periódicos nacionais, internacionais, conferências, simpósios, workshops, teses e dissertações. Entretanto, apesar desse crescimento, a maioria das pesquisas está focada apenas em demonstrar a capacidade do modelo em representar adequadamente as bacias hidrográficas brasileiras; sendo a maior parte delas limitadas pela falta de dados e de informações detalhadas, que descrevam satisfatoriamente a variabilidade espacial e temporal das regiões analisadas (BRESSIANI et al., 2015).

O maior percentual das publicações foi desenvolvido em bacias hidrográficas na região sul do Brasil, com destaque para o estado de Santa Catarina, seguida pela região sudeste e, mais recentemente, o Distrito Federal (GARBOSSA et al., 2011, CARVALHO, 2014). A maioria

dos estudos aborda a modelagem hidrológica, uma percentagem menor trabalha com questões sedimentológicas e, apenas uma pequena parcela refere-se à modelagem da qualidade da água. Em geral, essas pesquisas foram desenvolvidas em bacias menores do que 1000 km² (BRESSIANI et al., 2015), comumente resultando em estatísticas de desempenho melhores para dados de entrada mensal ou anual e desempenhos um pouco piores para dados diários (GARBOSSA et al., 2011).

Esses resultados também evidenciam a carência de dados para calibração, validação e desenvolvimento de modelagens no Brasil, especialmente, em termos de qualidade da água. Inegavelmente, as maiores aplicações voltadas para a hidrologia são o reflexo da maior disponibilidade de dados nessa área, sendo menor a quantidade de informações e o detalhamento dos dados no campo de sedimentologia e da qualidade da água, isso em razão das dificuldades em se realizar o monitoramento dessas últimas variáveis em relação à vazão e/ou nível de água.

De fato, muitos dos estudos descrevem dificuldades em obter dados para a modelagem com o SWAT (BARSANTI et al., 2003; GARRIDO, 2003; OLIVEIRA, OLIVEIRA e MEDEIROS, 2005a,b; PEREIRA, CAMPANA e EID, 2005; PAIVA e PAIVA, 2006; LINO et al., 2009; PAIM e MENEZES, 2009; BLAINSKI, GARBOSSA e MALUTTA, 2010; CARVALHO NETO, SRINIVASAN e RUFINO, 2011; GARBOSSA et al., 2011; MEIRA NETO, FONTES e MEDEIROS, 2011; FERNANDES, GALVÍNCIO e FREIRE, 2012; BONUMÁ et al., 2013; BRESSIANI et al., 2015) e, por certo, essa disponibilidade de um banco de dados adequado é, atualmente, um grande obstáculo para a difusão do emprego do modelo SWAT [e outros modelos de base física] nas diferentes regiões brasileiras (GARBOSSA et al., 2011).

Entre os estudos que procuraram adequar o modelo SWAT às características das bacias hidrográficas brasileiras está a pesquisa realizada por Bonumá (2011). Nesse estudo, o modelo foi aplicado na bacia do Arroio Lino (Rio Grande do Sul), com área de drenagem de 4,18 Km², para avaliar os processos hidrológicos, além da sedimentação e a transferência de fósforo. Essa bacia tem cultivo predominante de tabaco e problemas em relação à poluição por fósforo. A autora realizou uma adaptação no método de cálculo de erosão pelo SWAT, buscando melhor representação dos processos de deposição de sedimentos nas encostas e no canal. Essa modificação incorporou um termo de capacidade de transporte de sedimentos na paisagem, utilizando uma rotina de delineamento de posições relativas na encosta. A nova rotina resultou em melhor desempenho do modelo na calibração em relação ao SWAT original. As simulações

com o modelo modificado foram satisfatórias para o transporte de sedimentos em diferentes posições da paisagem; sugerindo que a integração da rotina de deposição de sedimentos aumenta a precisão do modelo de previsões em áreas mais íngremes e, ao mesmo tempo, melhora a capacidade de prever a distribuição espacial das áreas de deposição de sedimentos.

Na Tabela 10 são apresentados os resumos de resultados obtidos por diversos autores para modelagens da produção de sedimentos em bacias hidrográficas brasileiras, tendo por base o emprego do modelo SWAT.

Em geral, os estudos apresentam limitações nos dados disponíveis para a calibração e para a verificação das aplicações das estimativas sedimentológicas e; em razão disso, a maioria das pesquisas não realiza tais análises, ou desenvolve apenas a calibração e a verificação da vazão, simulando a posteriori os sedimentos, sem considerações de eficiência e comparação dos dados simulados aos observados.

Nas poucas vezes em que o processo de calibração-verificação da produção de sedimentos é realizado, os dados disponíveis englobam períodos extremamente curtos (cerca de 1 ou 2 anos) e, portanto, existe a possibilidade de que esse período não seja representativo de todo o domínio da variação temporal das partículas de sedimentos transportados nos diferentes regimes hidrológicos atuantes na bacia. Além disso, essa ausência de informações sedimentológicas e de qualidade da água (e mesmo de vazão para alguns locais) reflete-se também no período destinado ao aquecimento do modelo (conhecido por *warm-up*), responsável pelo equilíbrio das condições iniciais. De fato, muitos autores não fazem menção à destinação de um período de dados para essa finalidade.

Por tais características, os resultados de eficiência dos modelos ainda são classificados, em sua maioria, como insatisfatórios ou apenas bons, em especial para simulações a nível diário; sendo as conclusões obtidas utilizadas mais como indicadores qualitativos e para análises da distribuição espacial da produção de sedimentos na bacia, que para diagnósticos quantitativos mais aprofundados. Todavia, apesar dessas limitações, os autores frequentemente têm reportado indicativos de que o modelo SWAT pode sim representar uma promissora ferramenta para a estimativa dos processos hidrossedimentológicos em bacias hidrográficas brasileiras; havendo, entretanto, a necessidade de se vencer o desafio dessa limitação na disponibilidade de dados para calibração e verificação das possíveis aplicações do modelo, bem como, de melhorar a coleta de dados físicos e a parametrização do modelo.

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT

(Continua)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Oliveira e Medeiros (1999)	Rio Joanes (Bahia)	Avaliar as alterações hidrossedimentológicas provocadas pelos diferentes usos do solo	755,4	-	-	-	-	-	redução da vegetação nativa e o aumento da urbanização incrementaram as perdas de solo em aproximadamente 17% em 13 anos de simulações
Machado (2002)	Ribeirão dos Marinis (Piracicaba, São Paulo)	Simular o escoamento e a produção de sedimentos produzidos pela microbacia hidrográfica no biênio 1999/2000.	59,73	C: 1999-2000	-	-	C: -0,06 (1 ha), -0,13 (20 ha), 0,03 (30 ha), 0,78 (40, 60 e 80 ha), 0,74 (100 e 120 ha) e -1,63 (200 ha)	-	
Machado e Vettorazzi (2003)	Ribeirão dos Marinis (Piracicaba, São Paulo)	Avaliar a distribuição espacial da produção de sedimentos na microbacia hidrográfica	59,73	C: 1999/2000	-	-	C: 0,83	-	Houve períodos em que a produção de sedimentos foi superestimada em relação aos dados observados e, em outros, subestimada
Machado, Vettorazzi e Xavier (2003)	Ribeirão dos Marinis (Piracicaba, São Paulo)	Simular cenários alternativos de uso e ocupação da terra na microbacia hidrográfica e compará-los quanto à produção de sedimentos com o cenário de uso atual, para o biênio 1999/2000	59,73	C: 1999-2000 (calibração realizada em Machado e Vettorazzi, 2003a)	-	-	-	-	Cenários testados: i) no uso atual - mantida faixa de mata ciliar de 30 m em toda a extensão dos cursos d'água e de 50 m ao redor das nascentes e; ii) as pastagens nas encostas mais íngremes, com alto potencial erosivo, foram substituídas por vegetação florestal. Os dois cenários foram comparadas com as condições do cenário atual em termos de produção de sedimentos
Minoti et al. (2004)*	Rio Guabiobas		54,12	1999-2003					
Silva et al. (2004)*	Rio Canchim		15	1999-2003					
Moro (2005)	microbacia experimental do Ribeirão Marinis (São Paulo)	Aplicar o modelo SWAT na simulação da produção de sedimentos e do volume de escoamento superficial	59,73	1999-2000	-	-	C: 0,83	-	Foram criados diferentes cenários: i) Grupo 1: 6 cenários para os diferentes tipos de solo e; ii) Grupo 2: 7 cenários de uso de solo de acordo com o plano de informação de susceptibilidade do solo
Neves (2005)	Microbacia do Rio Bonito, (municípios de Descalvado e Porto Ferreira, São Paulo)	Determinar a erosão na microbacia, bem como a quantificar nitrogênio (N) e fósforo (P), utilizando o modelo SWAT	223	simulação 1993-2004. Não realizada calibração e verificação do modelo	-	-	-	-	Os resultados demonstraram que as práticas de Agricultura Genética e Pastagens, seguidas de Cana-de-açúcar, foram as culturas onde houve maior ocorrência de geração de sedimentos
Prado (2005)	Rio Jundiá-Mirim (Jundiá, São Paulo)	Simular a produção de sedimentos para diferentes cenários de uso do solo: i) preservação (mata); ii) uso do solo em 1972; iii) uso atual das terras (imagens ano 2001); iv) uso atual das terras (cenário iii), considerando preservação de todas as Áreas de Preservação Permanente (APP) e; simulação do uso e ocupação das terras a partir do cenário 3 (uso atual), considerando expansão urbana e industrial de 20% até 2020	120,15	-	-	-	-	-	Analisadas as diferenças na produção de sedimentos para a variação do uso do solo na bacia entre 1972 e 2001
Silva et al. (2005)*	Rio Bonito (São Paulo)		47,17	1992-2004					
Minoti (2006)	Rio Mogi-Guaçu (São Paulo)	Estimar a erosão e as cargas de sedimentos de microbacias hidrográficas, em diferentes cenários de uso e ocupação do solo	11,0317	-	-	-	-	-	Cenários testados: i) original (vegetação natural em toda a bacia), ii) atual (uso do solo atual) e, iii) cana-de-açúcar em toda a bacia. O SWAT foi sensível às mudanças de cenários de uso do solo (sem calibração)

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (continuação)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Silva et al. (2006)*	Rio Beja-Flor e Rio Jataí (São Paulo)		110	-		-	-	-	
Machado, Xavier e Vettorazzi (2007)	Rio Marins (Piracicaba, São Paulo)	Avaliar o efeito de diferentes níveis de discretização em uma bacia, na simulação da produção de sedimentos pelo modelo SWAT	59,73	simulação: 1999-2000	-	-	C: 0,03 e 0,78 entre os diferentes níveis de discretização para a bacia	-	Quando a discretização é mais refinada (maior número de sub-bacias), há um aumento da produção de sedimentos, ocorrendo o contrário quando a discretização da bacia é menor
Rodrigues e Reis (2007)	Rio Coruripe (Alagoas)	Avaliar a produção de sedimentos na bacia hidrográfica	1562	Simulação: 2004 a 2006	-	-	-	-	Não foram levantados dados de campo para validar os resultados das simulações. Maiores taxas de erosão nas áreas urbanas
Rollof et al. (2007)*	Rio Toledo e Rio Ajuricaba (Paraná)		65 (Toledo) 16,50 (Ajuricaba)	simulação: 1998-2004		-	-	-	
Adriolo et al. (2008)	Rio Apucarantina (Paraná)	Calibrar e validar modelo SWAT para simular a produção e o transporte de sedimentos	504	C: 01/01/2000 a 31/07/2005 V: 01/01/1988 a 31/12/1999 Série: 01/01/1988 a 31/07/2005	-	C=0,20 V=-2,36 Série = -1,86	C: 0,415 V: 0,617 Série: 0,606	-	
Baltokoski (2008)	duas microbacias contíguas, dos rios Conrado e Pinheiro (Paraná)	Avaliar a aplicabilidade do modelo SWAT na previsão de escoamento superficial, na produção de sedimentos e no fluxo de massa do fósforo total, utilizando técnicas de análise de sensibilidade e calibração	24,11 (rio Conrado) e 28,86 (rio Pinheiro)	simulação: 2003/2005 Sedimento: 11/4/2003 a 27/07/2005 As médias anuais e mensais de vazão, sedimentos e fósforo total calculadas foram comparadas com os dados observados (após a calibração SWAT)	-	-	-	-	O desvio do evento simulado (Dv) após calibração da vazão foi de -0,12%, resultado, considerado muito bom. O modelo também identificou espacialmente a origem dos sedimentos, por sub-bacias, de maneira satisfatória
Lopes e Kobiyama (2008)	M2 Experimental (Rio Negrinho, Santa Catarina)	Analisar o equilíbrio hidrossedimentológico em uma microbacia experimental (M2) com o modelo SWAT	8,56	C: junho e dezembro de 2007 (para vazão somente)	janeiro de 2006 a dezembro de 2007	-	-	-	
Lopes (2008)	2 bacias com vegetação nativa (N1 e N2), 2 com reflorestamento de pinus, (P1 e P2), 1 com agricultura (A), e 2 mistas (M1 e M2), localizadas nos municípios de Mafra e Rio Negrinho (Santa Catarina)	Analisar a produção de água e sedimentos em microbacias hidrográficas experimentais, utilizando o modelo SWAT	-	C: 12/05/07 a 25/11/07 (N1), 01/02/07 a 22/06/07 (N2), 12/02/07 a 24/06/07 (P1), 01/05/07 a 22/10/07 (P2), 17/12/07 a 03/03/07 (A), 18/01/08 a 25/03/08 (M1), 01/02/07 a 30/06/07 (M2) V: 26/11/07 a 26/04/08 (N1), 01/08/07 a 20/11/07 (N2), 17/07/07 a 30/04/08 (P1), 23/10/07 a 19/04/08 (P2), 04/03/08 a 18/05/08 (A), 03/04/08 a 18/05/08 (M1), 01/07/07 a 31/12/07 (M2)	-	-	C manual: -0,59 (N1), 0,03 (N2), 0,09 (P1), -0,33 (P2), 0,36 (A), 0,53 (M1) e 0,15 (M2) C automática: 0,42 (N1), 0,47 (N2), -4,4 (P1), -1,39 (P2), 0,37 (A) V manual: -7,58 (N1), 0,26 (N2), 0,06 (P1), -1,34 (P1), -134 (P2), -0,15 (M1) e 0,18 (M2) V automática: -1,31 (N1), 0,23 (N2), -0,24 (P1), -1,88 (P2), 0,51 (A)	-	Foram observadas limitações do modelo para pequenas bacias, devido à perda de sensibilidade na resposta da bacia e ao grande número de parâmetros necessários para calibração
Marchioro (2008)	Rio Santa Maria (São José de Ubá, Rio de Janeiro)	Simular a vazão e a produção de sedimentos na bacia	13,56	C: biênio 2006-2007 (vazão) e dezembro de 2006 a dezembro de 2007 para CSS	-	C: -6,11 V: 0,02	-	-	
Bonumá t al. (2009)	Arroio Lino (Agudo, Rio Grande do Sul)	Avaliar os processos erosivos e a produção de sedimentos em uma bacia hidrográfica rural por meio do modelo SWAT	3,2	simulação: 2004 e 2005	-	C: -0,33	C: 0,70	-	O modelo apresentou bons resultados de ajuste a nível mensal. Os resultados na escala diária foram inferiores
Gibertoni et al. (2009)	bacia do rio Nhundiaquara, Baía de Antonina (Paraná)	Avaliar a produção hidrossedimentológica da bacia hidrográfica do rio Nhundiaquara, drenante à Baía de Antonina	516 (monitorados 351)	C: 01/09/1975 - 31/12/1991 V: 01/01/1992 - 30/06/2007	-	C: 0,41 V: 0,524	C: 0,936 V: 0,921	-	Avaliada descarga sólida. Cenários analisados: i) Natural (área de agricultura e pecuária substituída por florestas); ii) Pessimista: todas as áreas, exceto áreas urbanas e água, foram substituídas por agricultura e pecuária; e iii) Provável: cerca de 25% da bacia foi considerada com uso de agricultura e pecuária.

Tabela 10- Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (continuação)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km ²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos			Observações
						C: calibração V: verificação	Diário	Mensal	
Lino (2009)	Rio Preto (Santa Catarina)	Analisar a dinâmica hidrossedimentológica da bacia hidrográfica, utilizando o modelo SWAT	1000,41	C: 14/12/1993 à 31/12/1997 (vazão somente) V: não realizada	-	-	-	-	Cenários simulados: a) uso e cobertura atual; b) mata nativa; c) agricultura; d) reflorestamento e; e) uso e cobertura atual sem reservatórios
Lubitz (2009)	Rio Concórdia (Lontras, Santa Catarina)	Avaliar a aplicabilidade do modelo SWAT à bacia experimental	30,74	C sedimentos: 16/11/2008 a 15/01/2009 e de 22/03/2009 a 21/05/2009	-	-0,03 (sem calibração) e -0,01 (calibração)	-0,49 (sem calibração) e 0,84 (calibração)	-	
Paim e Menezes (2009)	Rio Tijucas (Santa Catarina)	Testar a aplicabilidade do modelo SWAT na bacia hidrográfica para quantificar a produção de água e sedimentos	2.840	simulação: 1991 a 2001	-	-	-	-	
Uzeika (2009)	Bacia de Arvorezinha (Rio Grande do Sul)	Avaliar a eficiência e as limitações do modelo SWAT sem calibração para simular o escoamento e a produção de sedimentos em diferentes escalas temporais (diário, mensal e anual)	1,19	2002 a 2006	2 anos antes do período analisado	C: -12,20 (2002); -17,36 (2003); -7,77 (2004); -9,82 (2005) e -145,58 (2006)	C: -77,38 (2002); -27,89 (2003); -7,06 (2004); -6,53 (2005) e -241,63 (2006)	-	Os resultados para previsão da produção de sedimentos foram insatisfatórios, a nível diário e mensal, com superestimativa da produção anual em + de 100% Cenários futuros (2007 a 2050): i) toda a bacia com floresta; ii) plantio de fumo e repouso no inver (sem cultivo) e; iii) adubação verde de inverno e implantação da cultura do fumo em cultivo mínimo;
Xavier (2009)	Rio Manso (Mato Grosso)	Avaliar a produção e a distribuição de sedimentos na bacia	105.553	simulação: 1994 a 1998, mas somente foram utilizados os dados de 1994. Sem calibração	-	-	-	-	Cenários: i) agricultura em estágio de crescimento; ii) uso do solo com agricultura genérica (ocupação hipotética da bacia com agricultura); iii) uso do solo com pastagem (ocupação hipotética da bacia com pastagem); iv) uso original do solo (ocupação hipotética da bacia com vegetação nativa) e; v) uso do solo atual
Blainski, Garbossa e Malutta (2010)	Rio Lajeado do Fragosos (Concórdia, Santa Catarina)	Avaliar a distribuição da produção de sedimentos e vazão para diferentes cenários agrícolas (i- atual, ii- reflorestamento nativo; iii- introdução de culturas anuais em sistema de plantio convencional e; iv- introdução de culturas anuais em sistema de plantio direto)	58,75	período simulação: 2005 a 2009	Modelo calibrado para vazão apenas	-	-	-	# Os dados de perda de solo simulados não foram comparados com dados medido # As alterações no uso e ocupação do solo ocasionam diferenças significativas na perda de solo por erosão hídrica
Bonumá et al. (2010)	Arroio Lino (Rio Grande do Sul)	Avaliar o balanço hídrico e a produção de sedimentos na bacia hidrográfica	3,2	C: janeiro a dezembro de 2005 V: janeiro a dezembro de 2004	janeiro de 2002 a dezembro de 2003	V: -0,33	V: 0,70	-	As estatísticas calculadas mostraram desempenho bem inferior para as simulações diárias de sedimentos em relação às obtidas para os períodos mensais
Leis e Calijuri (2010)	Rio São Bartolomeu (Minas Gerais)	Identificar as zonas de maior erosão em relação ao uso e tipo de solo	54,22	C: dezembro/2006 a março/2008	-	-	-	-	
Pereira et al. (2010)*	Cachoeirinha (Minas Gerais)		-	simulação: 1979-2008	-	-	-	-	
Santos (2010)	Rio Potengi (Rio Grande do Norte)	Avaliar a aplicabilidade do modelo SWAT para estimar a distribuição da produção de sedimentos ao longo da bacia e a sua contribuição para o estuário, fazendo também um paralelo com a susceptibilidade à erosão hídrica	4100	simulação: 1997 a 2001 Não realizada calibração e validação	-	-	-	-	3 cenários com composições de cobertura do solo diferentes, com base nas formas de interferência humana: agricultura, pastagem e nenhuma interferência (background)
Santos et al. (2010)	Rio Apucarantina (Paraná)	Simular a produção e o transporte de águas e sedimentos (suspensos e de fundo)	504	simulação: 1988-2005	-	C: 0,20 e - V: -2,36 e -	C: 0,42 e - V: 0,62 e -	-	Cenários: i) condição atual sem prática de conservação; ii) a condição atual com mata ciliar integral; iii) agricultura com prática de conservação do solo e mata ciliar integral; iv) 100% das florestas; v) agricultura sem as práticas de conservação do solo e com mata ciliar integral; vi) 100% agricultura sem práticas de conservação do solo e; vii) 100% agricultura com práticas de conservação do solo

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (continuação)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Schultz, Souza e Santos (2010)	bacia do Altíssimo Rio Negro (Santa Catarina)	Simular a produção e transporte de sedimentos diários na bacia	788	1994-2004	-	C: 0,38	C: 0,86	-	
Bonumá (2011)	Arroio Lino (Agudo, Rio Grande do Sul)	Avaliar os processos hidrológicos, a produção de sedimentos e a transferência de fósforo na bacia hidrográfica	4,18	C: janeiro de 2001 a dezembro 2005	janeiro a dezembro de 2005	-	C: 0,7 (rotina modificada) e -0,14 na rotina original V: -1,37 (rotina modificada) e -12,3 (rotina original)	-	Para representar melhor os processos de deposição de sedimentos nas encostas, a rotina do modelo SWAT foi modificada com a incorporação de um termo de capacidade de transporte de sedimentos na paisagem
Ferrigo, Minoti e Koide (2011)	Bacia do Córrego de Capão Comprido (Distrito Federal)	Analisar espacialmente os processos hidrossedimentológicos na bacia, com base na aplicação do modelo SWAT	16,6	01/01/2003 a 31/12/2005 (usados para comparação dos dados de vazão)	-	-	-	-	Foram analisados 3 cenários: (1) sem ação antrópica; (2) atual da bacia; e (3) com a bacia inteiramente ocupada por agricultura e urbanização. Os dados de vazão simulados foram comparados aos observados
Lessa (2011)	Rio Pardo (Botucatu, São Paulo)	Avaliar a distribuição espacial da produção de sedimentos produzida pela parte inicial da bacia hidrográfica, utilizando o modelo hidrológico SWAT	148,76	C: 01 de setembro de 1996 a 30 de novembro de 1997 (para vazão somente)	-	-	-	-	Simulado um cenário de acordo com as determinações do Código Florestal Brasileiro. O cenário do Código Florestal serviu como controle da taxa de produção de sedimentos
Marchioro et al. (2011)	Córrego Santa Maria (São José de Ubá, Rio de Janeiro)	Analisar a distribuição espacial média da produção de sedimentos na bacia experimental	13,56	C: dezembro de 2006 e dezembro de 2007	-	-	-12,4516 (sem calibração) e -6,1136 (com calibração)	-	As áreas com maior produção de sedimentos ocorrem nas HRUs com domínio das pastagens associadas às declividades, entre 25% e 57%, comprimentos de encostas entre 15 e 28 m, e às características do ARGISSOLO VERMELHO AMARELO, NEOSSOLO LITÓLICO (RLve) e CAMBISSOLO HÁPLICO
Pinto (2011)	Ribeirão Lavrinhas (Serra da Mantiqueira, Minas Gerais)	Aplicar o modelo SWAT na simulação do escoamento, produção e transporte de sedimentos e na qualidade da água e; simular cenários alternativos de uso do solo, com intuito de reduzir a produção e o transporte de sedimentos na bacia	6,88	C: setembro de 2006 a agosto de 2008 (vazão e sedimentos) V: agosto de 2008 a setembro de 2010 (vazão e sedimentos) Simulação de nutrientes e qualidade da água: setembro de 2007 a julho de 2009	-	C: 0,68 V: 0,65	C: 0,68 V: 0,66	-	Simulados 2 cenários: i) substituição de pastagens por eucalipto e; ii) uso atual do solo implementando mata ciliar ao longo de toda a rede de drenagem. Redução de 40% e 38% na produção de sedimentos para i e ii
Silva et al. (2011)	Rio Colônia (Bahia)	Estimar as perdas de solo na bacia nos últimos 27 anos, utilizando o modelo SWAT e; prever as perdas de solo para 2 cenários teóricos de preservação: cobertura do solo com mata e manutenção das áreas de preservação permanente	100	simulação: 1975 a 2002	-	-	-	-	A variação nas perdas de solo por sub-bacia é atribuída, sobretudo, ao tipo de solo, às condições de relevo e às formas de uso
Kuwajima (2012)	Reservatório do Lobo, municípios de Itirapina, Brotas e São Carlos (São Paulo)	Avaliar a aplicabilidade do modelo SWAT como ferramenta para a estimativa de assoreamento em reservatórios	227	C: 1977 a 1985 (cenário i) e 1996 a 2006 (cenário ii). Calibração somente para vazão	-	4 anos iniciais replicados (cenário i) e 3 anos iniciais replicados (cenário ii)	-	-	Simulados 2 cenários: i) 18/03/1977 até 31/03/1985; ii) 1/01/1996 até 01/01/2006. Cenário i) não foi adequado (falhas dados de vazão) e cenário ii) indica possibilidade de representação dos sedimentos (não calibrado para sedimento)
Lelis et al. (2012)	Rio São Bartolomeu (Minas Gerais)	Análise de sensibilidade e calibração dos parâmetros para previsão da vazão e da produção de sedimentos	54,22	-	-	-	-	C: 0,808 V: 0,63	

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (continuação)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Malutta (2012)	Rio Negrinho (municípios de Rio Negrinho e São Bento do Sul, Santa Catarina)	Analisar espacialmente os processos hidrossedimentológicos na bacia	308	série: 1980 a 2010 (usados a partir de 1983) C: outubro de 2007 a novembro de 2008 (vazão) e 21 de maio de 2010 a 31 de agosto de 2010 (sedimento) V: janeiro de 2009 a novembro de 2010 (vazão)	1980 a 1982	-0,25 (sem calibração) C: 0,43	-	-	
Rocha et al. (2012)	Bacia de São Bartolomeu (Viçosa, Minas Gerais)	Avaliar a contribuição das práticas de conservação na redução do escoamento e das perdas de solo e de nutrientes, utilizando o modelo SWAT	54	simulação: outubro de 2007 a setembro de 2008	-	-	C: 0,9	-	As práticas de conservação consideradas: descanso da pastagem, cultivo de cotomo, rotação de culturas e culturas intercalares, otimização e uso eficiente de fertilizantes e adubos, revegetação e; terraços. Para a área urbana foi utilizado pavimentos permeáveis, poços de infiltração e telhados verde
Uzeika et al. (2012)	Bacia de Arvorezinha (Rio Grande do Sul)	Avaliar a eficiência e as limitações do modelo SWAT sem calibração para simular o escoamento e a produção de sedimentos em diferentes escalas temporais (diário, mensal e anual)	1,19	2002 a 2006	2 anos antes do período analisado	C: -12,20 (2002); -17,36 (2003); -7,77 (2004); -9,82 (2005) e -145,58 (2006)	C: -77,38 (2002); -27,89 (2003); -7,06 (2004); -6,53 (2005) e -241,63 (2006)	-	Os resultados para previsão da produção de sedimentos foram insatisfatórios, a nível diário e mensal, com superestimativa da produção anual em + de 100%
Aragão et al. (2013)	sub-bacia do Rio Japarutuba Mirim (Sergipe), nas seções de medição das estações Fazenda Pão de Açúcar (PA) e Fazenda Cajueiro (CJ)	Calibrar o modelo SWAT, e realizar análise de sensibilidade dos parâmetros para simular o escoamento superficial e a erosão do solo. Verificar os resultados da transposição dos parâmetros calibrados de uma seção de medição para a outra, e vice-versa, entre as duas bacias	137,3 (PA) e 277,8 (CJ)	C: 1986-1988 para vazão V: 1989-1990 para vazão simulação da produção de sedimentos: 1986 a 2000	dados de 1985	-	-	-	Na simulação de sedimentos, o SWAT somente foi usado para análise qualitativa, sem comparação entre dados simulados e observados (dados ausentes)
Arroio Junior (2013); Arroio Junior, Kuwajima e Mauad (2013)	Rio Itaqueri (São Paulo)	Realizar um diagnóstico da produção de sedimentos e de seu transporte na bacia hidrográfica	220	simulação: 1/1/1992 até 12/31/2011 1995 a 2011: usados para estimativa da produção de sedimentos	3 anos iniciais da série para aquecimento	-	-	-	Não realizada calibração e verificação do modelo
Conceição et al. (2012)	Lajeado dos Fragosos (Concórdia, Santa Catarina). Três seções de monitoramento: montante (SM), intermediária (SI) e jusante SJ	Avaliar, com dados medidos em diferentes escalas na bacia rural e simulados pelo modelo SWAT, o efeito do uso misto do solo e o manejo com aplicação de dejetos de suíno, no transporte do sedimento em suspensão	1,67 (SM); 30,35 (SI) e 53,03 (SJ)	período simulado: 2000 a fevereiro de 2012 2010, 2011 e início de 2012: usados para avaliar o impacto da cobertura e ocupação do solo sobre a produção de sedimento	primeiros anos iniciais utilizados para aquecimento	C: 0,49	-	-	
Lubitz, Pinheiro e Kaufmann (2013)	Ribeirão Concórdia (Santa Catarina)	Avaliar a capacidade do modelo SWAT em simular o transporte de sedimentos, nitrogênio e fósforo	30,74	período simulado: 20006 a 2009 C: 01/04/06 a 30/09/06 e 16/11/08 a 15/05/2009		C: -0,01	C: 0,84		As simulações diárias revelaram que limitações nos dados de entrada e na parametrização afetaram profundamente a eficiência do modelo
Perazzoli, Pinheiro e Kauffman (2013)	Ribeirão Concórdia (Santa Catarina)	Simular diferentes cenários de uso do solo para a bacia hidrográfica, utilizando o modelo SWAT, e analisar os efeitos dessas mudanças no fluxo de água e de sedimentos	30,74	simulação: 2001 a 2010 C: janeiro de 2007 a dezembro de 2010 (vazão) e de novembro de 2008 a maio de 2009 (sedimentos) V: janeiro de 2011 a dezembro de 2011	2001 a 2006	C: 0,308	C: 0,832	-	Cenários simulados: i) agricultura, ii) mata nativa e, iii) pastagem. O cenário agrícola apresentou maior aumento da produção de sedimentos em relação ao estado atual de uso do solo
Rocha (2013)	Rio Piranga (Minas Gerais)	Modelagem ambiental de uma bacia hidrográfica em nível de escala maior, acompanhada da calibração e verificação do SWAT através do algoritmo de otimização SUFI-2 que permita a identificação de áreas críticas, do ponto de vista da vazão e produção de sedimentos	6600	simulação: 1999 a 2011	-	-	V: 0,81 (sub-bacia 1); 0,86 (sub-bacia 2) e 0,77 (sub-bacia 3)	-	
Santos et al. (2013)	Rio Potengi (Rio Grande do Norte)	Avaliar a aplicabilidade do modelo SWAT para estimar a distribuição da produção de sedimento ao longo da bacia hidrográfica	4100	simulação: 1997-2001	-	-	-	-	

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (continuação)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km ²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Silva et al. (2013)	Bacia de Mamuaba, sub-bacia da bacia do do Rio Gramame (João Pessoa, Paraíba)	Avaliar a erosividade, o escoamento superficial e as taxas de erosão do solo usando o modelo SWAT	60,9	simulação: 1969 a 1982 C: janeiro de 1969 a dezembro de 1977 (vazão somente) V: janeiro de 1978 a abril de 1982 (vazão somente)	-	-	-	-	
Strauch et al. (2013)	Rio Pipinipau (Distrito Federal)	Investigar como as melhores práticas de manejo agrícola podem contribuir para a gestão sustentável dos recursos hídricos e para a proteção do solo na região	188	C: 01/2004 a 12/2006 V: 01/2007 a 06/2009 período total: 01/2004 a 06/2009	-	C: NS variou entre -0,10 e 0,42 e NS corrigido variou entre 0,42 e 0,85 para diferentes entradas de precipitação V: NS variou entre -9,16 e -0,67 e NS corrigido variou entre -1,23 a -0,08 período total: NS variou entre -0,09 e 0,34 e NS corrigido variou entre 0,47 e 0,73	-	-	
Carvalho (2014)	Bacia do Alto Rio Jardim (Distrito Federal)	simular a vazão e a descarga sólida em suspensão em uma bacia hidrográfica agrícola do Cerrado brasileiro	104,86	C: 01/07/2006 a 30/06/2008 V: 01/07/2011 a 30/06/2013 para dados de vazão	01/07/2003 a 30/06/2006	-	C: 0,26	-	O modelo simula bem as vazões, mas o mesmo não aconteceu com a produção de sedimentos
Carvalho Neto et al. (2014)	Rio Una (Pernambuco)	Aveniguar as estimativas de perdas de solo para diferentes valores do Fator de Cobertura do Solo. A análise da quantidade média de erosão anual de sedimentos, entre os anos de 2000 a 2008 (todo o período simulado) foi realizada para valores do Fator C da cana de açúcar de 0,001; 0,05 e; 0,3066	6.704	C: 2000 a 2004 V: 2005 a 2008	-	-	-	-	A amplitude das estimativas de erosão obtidas mostra a necessidade da atribuição de um valor de Fator C que mais bem represente as condições ao qual é aplicado
Castro (2014)	Rio das Pedras (Guarapuava, Paraná)	Analisar a produção sedimentos, com auxílio do programa de modelagem hidrossedimentológico SWAT	332,01	-	-	C: 0,48	-	-	O modelo apresentou viabilidade de aplicação em condições brasileiras
Ferrigo et al. (2014)	Bacia experimental do Córrego de Capão Comprido (Distrito Federal)	Avaliar os possíveis impactos das alterações na precipitação, que podem ser causadas pelas mudanças climáticas, e no uso do solo sobre a produção de sedimentos. Foram avaliados 4 cenários de alteração na precipitação baseados no relatório do Painel Intergovernamental de Mudanças Climáticas e dois cenários de mudanças de uso do solo baseados na intensificação da urbanização e do desenvolvimento agrícola.	16,6	2005-2013: usados para comparação dos dados de vazão observados ao simulado (sem calibração) 2008/2009: usados para um breve comparativo dos dados de descarga sólida	-	-	-	-	
Galharte, Vilella e Crestana (2014)	Microbacia hidrográfica do ribeirão das Guabrobas (São Carlos, São Paulo)	Estimar a produção de sedimentos por meio de modelo de simulação (combinação dos modelos CLUE-S e SWAT), em cenários do ano de 2025 da microbacia hidrográfica	51,46	-	-	-	-	-	Testados 2 cenários: i) expansão da cana-de-açúcar e; ii) expansão da laranja
Iensen, Schultz e Santos (2014)	Bacia do rio Apucarantina (Minas Gerais)	Simular os impactos das mudanças climáticas na dinâmica hidrossedimentológica, considerando os cenários de mudanças climáticas A2 (pessimista sobre as emissões de gases de efeito estufa) e B2 (otimista sobre as emissões de gases de efeito estufa), desenvolvidos pelo IPCC	504	Série: 1987 a 2012 C: 2000 a 2012 V: 1987 a 2000	-	C: 0,38 V: 0,47	C: 0,60 V: 0,70	-	Os resultados mostram diminuição significativa na produção de sedimentos e do escoamento, para ambos os cenários A2 e B2, devido à redução da precipitação e o aumento previsto na temperatura
Marchioro et al. (2014)	Córrego Santa Maria (São José de Ubá, Rio de Janeiro)	simular o efeito de um cenário ambiental ideal (reflorestamento nas áreas estabelecidas pelo Código Florestal) na produção média de sedimentos e na CSS entre o período de 2005 a 2007	13,56	C: abril de 2005 a agosto de 2006 V: dezembro de 2006 a setembro de 2007	-	-	V: -12,4516 (sem calibração) e -6,1136 (com calibração) para CSS	-	O reflorestamento minimiza a produção de sedimentos e a CSS
Medeiros e Silva (2014)	Bacia Experimental de São João do Cariri (Paraíba)	Analisar a aplicabilidade do modelo SWAT utilizando dados de alta resolução espacial, para analisar o comportamento das perdas de água e solo em uma bacia do semiárido nordestino	13,5	simulação: 2004 a 2006	-	-	-	-	

Tabela 10 - Resumos dos resultados de estudos hidrossedimentológicos em bacias hidrográficas brasileiras, empregando o modelo SWAT (fim)

Referência	Localização (bacia)	Objetivo do estudo	Área de drenagem (Km ²)	Período simulado C: calibração V: verificação	Período de aquecimento (Warm-up)	NS para produção de sedimentos C: calibração V: verificação			Observações
						Diário	Mensal	Anual	
Santos et al. (2014)	Rio Tapacurá (Pernambuco)	Estimar a produção de sedimentos e analisar sua distribuição espacial na bacia, utilizando o modelo SWAT	472	simulação: 1995 a 2008 C: 1995–2001 (somente vazão) V: 2002–2008 (somente vazão)	1992 a 1994	-	-	-	A maior produção de sedimentos está associada à presença de plantios de cana-de-açúcar e outros tipos de cultivos, além de atividades de pecuária
Silva e Medeiros (2014)	Bacia Experimental de São João do Cariri (porção semiárida do Estado da Paraíba)	Analisar a variabilidade espacial e temporal do escoamento superficial e da produção de sedimentos, empregando o modelo SWAT e dados de uso do solo com alta resolução espacial (1 m) e de altitude (30 m)	13,5	C: 2601/2004 a 31/12/2006	-	-0,32	-	-	
Silva (2014)	Rio Mundaú (Pernambuco e Alagoas)	Avaliar a produção de sedimentos na bacia, utilizando o modelo SWAT	4.126	C: 1998 a 2002 (vazão e sedimentos) V: 2003 a 2007 (vazão e sedimentos)	-	-1,05 e -1,22 (antes da calibração e verificação) C: 0,63 V: 0,53	-	-	Modelo satisfatório para a produção de sedimentos. Tendência a subestimativa Cenários futuros (atual a 2040): i) atual: dados climáticos do período das estações climatológicas utilizadas no período de 1979 a 2010, ii) futuro: pessimista, com decréscimo nos valores de precipitação em -10% e acréscimo entre 0,5° e 1°C na temperatura
Silva, Dantas e Silva (2014)	Rio Taperoá (Paraíba)	Simular a produção de sedimentos na bacia, mediante geotecnologias e o modelo SWAT	5.658	simulação: 1973 a 1990 C: 1973 a 1982 (somente vazão) V: 1983 a 1990 (somente vazão)	1970 a 1972	-	-	-	
Veiga (2014)	Córrego Samambaia (Goiania)	Calibrar o modelo SWAT para estimativa de fluxo e CSS e estimar a produção de sedimentos na bacia	31,745	simulação: 01/01/2003 a 01/12/2013 C: setembro a dezembro de 2013 (sedimento) e fevereiro a dezembro de 2013 (vazão)	3 anos	C: 0,88	-	-	
Dantas et al. (2015)	Rio Taperoá (Paraíba)	Estimar a produção de sedimentos na bacia utilizando o modelo SWAT	5.658	C: janeiro de 1973 a dezembro de 1982 (vazão) V: entre janeiro de 1983 e dezembro de 1990	3 anos (1970 a 1972)	-	-	-	A estimativa da produção de sedimentos foi calculada para toda a série de dados, com exceção dos três primeiros anos de aquecimento do modelo
Fernandes (2015)	Rio São Francisco (Região Nordeste). A bacia foi dividida em seis projetos: Três Marias, Sobradinho, Itaipava, Paulo Afonso, Xingó e Foz	Avaliar a viabilidade do uso do modelo SWAT para estimativa da vazão e da produção de sedimento na bacia	639.219	C: 1992 a 2012 (para vazão somente)	1988 a 1991	-	-	-	No geral o modelo apresentou bons resultados estatísticos. A produção de sedimentos durante o período analisado apresenta tendência de superestimativa
Silva, Silva e Silva (2015)	Bacia Hidrográfica do Submédio Rio São Francisco	Avaliar o impacto da mudança na cobertura do solo sobre o aporte de sedimentos nas condições atuais de uso de solo a partir de simulações usando o modelo SWAT	110.446	simulações: 1993 a 2010	-	-	-	-	
Siqueira e Alcântara (2015)	Três pequenas bacias (cias - Riacho das Cabras, José Gonçalves e de Marias Pretas), integrantes da bacia experimental de Poço de Pedras (Paraíba)	Avaliar a estimativa da produção de sedimentos por meio do SWAT para bacias não instrumentadas do semiárido brasileiro com o intuito de subsidiar estratégias de conservação e o planejamento ambiental	variando de 2,93 a 11,17	simulação: 1998 a 2012. Sem calibração	-	-	-	-	
Zanin (2015)	Bacia hidrográfica do Rio Preto no planalto Norte Catarinense (municípios de Rio Negrinho, Mafra e Itaiópolis, Santa Catarina)	Avaliar e modelar a dinâmica hidrossedimentológica de duas bacias embutidas com represamento hídrico	965,48	simulação: 2009 a 2014 C: 2013 V: 2014	2009, 2010, 2011 e 2012	-	NS: -1,202 (sem calibração) e - 277,155 (com calibração da vazão) C sedimento: 0,677 V: 0,857	-	
Zanella (2016)	Bacia hidrográfica à montante da PCH Costa Rica (Mato Grosso do Sul)	Aplicar e avaliar modelos de predição de aporte de sedimentos na bacia hidrográfica, gerados pelos softwares SWAT e InVEST e; propor metodologia para a mitigação de áreas degradadas por processos erosivos acelerados, visando à diminuição do assoreamento e o aumento na geração de energia dessa hidrelétrica	1.200	2012 e 2013. Calibração não realizada (escassez de dados)	-	-	-	-	A ausência de série histórica de dados hidrossedimentológicos da bacia foi um fator limitante para a calibração e a validação da modelagem da perda de solo pelos modelos

Obs: Foram apresentados apenas os resultados de desempenho do modelo para a previsão da produção de sedimentos, embora os autores tenham realizado também a calibração para vazão e/ou nutrientes

* Informações obtidas de Garbossa et al. (2011). Trabalhos originais não localizados.

Fonte: autora

Nesse cenário é, pois, imprescindível que sejam desenvolvidas técnicas e metodologias alternativas, que possibilitem a construção de um banco de dados menos limitado, com informações sedimentológicas contínuas, em especial para aquelas regiões com restrições significativas de dados de monitoramento; de maneira que se possa assegurar a melhoria dos processos de calibração e de verificação dos modelos de base física, atualmente disponíveis.

Um caminho possível para essa jornada passa pelo uso de sistemas alternativos de monitoramento da CSS e na subsequente transformação desses dados, de maneira eficiente, em séries contínuas de monitoramento. A metodologia proposta a seguir busca contribuir nesses primeiros passos em direção à melhoria dos sistemas de monitoramento hidrossedimentológico brasileiro, em especial, para aqueles locais com limitações na quantidade de dados disponíveis.

3 MATERIAIS E MÉTODOS

Essa pesquisa compreendeu o monitoramento das variáveis envolvidas nos processos hidrossedimentológicos na bacia do Taboão, e a posterior modelagem da produção de água e de sedimentos com o modelo SWAT.

O estudo também desenvolveu um modelo baseado em RNAs, que possibilita a eficiente conversão dos valores de turbidez e de nível de água monitorados em valores de CSS; promovendo, com isso, o aumento da eficiência das redes de monitoramento sedimentológicas nessa bacia hidrográfica. Os dados convertidos foram empregados como entradas no *software* SWAT-CUP para realizar a calibração e a verificação dos processos hidrossedimentológicos simulados pelo modelo SWAT.

Em razão de falhas nos dados de precipitação, nível de água e turbidez, também foram desenvolvidos modelos de RNAs para o preenchimento dessas falhas. Para tal, foram utilizadas informações de precipitação e dados de níveis de água monitorados no exutório da bacia e também, em bacias embutidas e/ou adjacente à bacia do Taboão.

Para todos os modelos de RNAs desenvolvidos considerou-se uma rede do tipo *feedforward*, com três camadas, sendo utilizados na execução do processo de treinamento algoritmo retropropagativo (apresentado por RUMELHART, HINTON e WILLIAMS, 1986) e técnicas de aceleração heurística (VOGL et al., 1988).

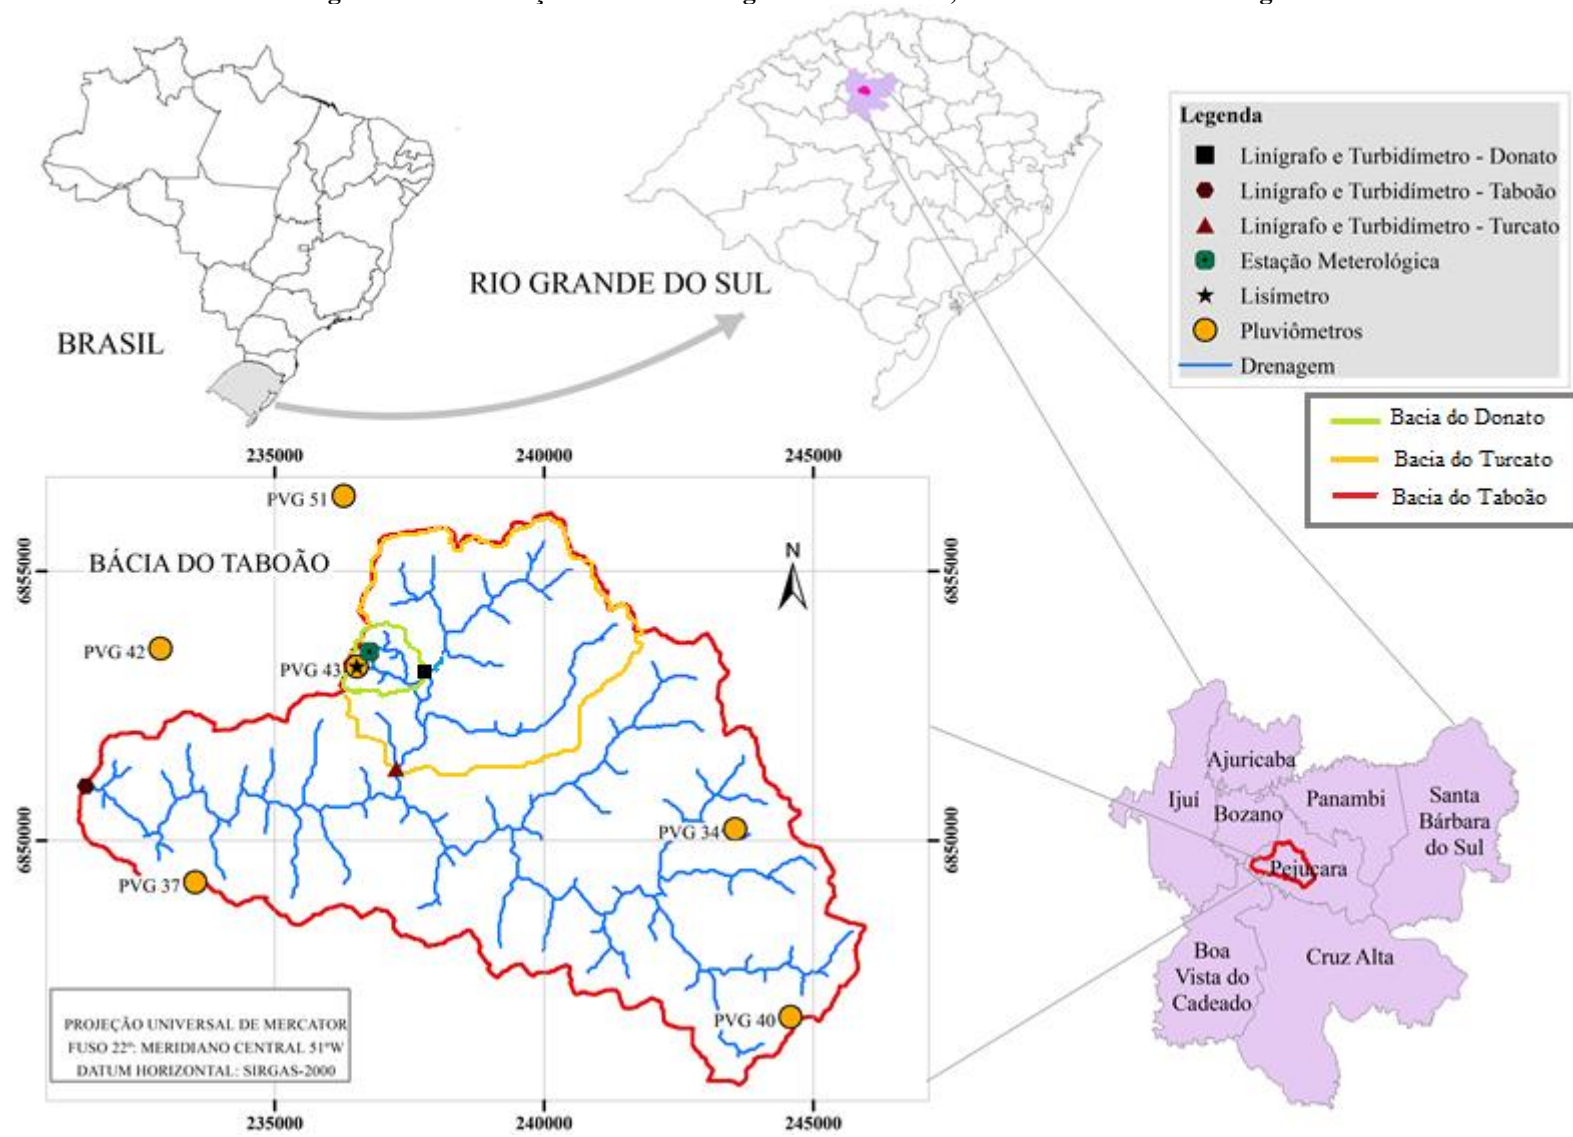
3.1 Localização da área de estudo e características climáticas

A área de estudo compreendeu a bacia hidrográfica do Taboão ($A=78 \text{ km}^2$), localizada no município de Pejuçara, sobre o derrame basáltico sul-rio-grandense, na região do Planalto Médio do estado do Rio Grande do Sul (Brasil). A altitude máxima registrada nessa bacia é igual a 485 m, com desnível de 154,3 m.

Na Figura 10 é mostrada a localização da bacia hidrográfica do Taboão, no contexto brasileiro e regional, além da localização dos pontos monitorados dentro da bacia.

O derrame basáltico sul-rio-grandense cobre uma área aproximada de 230.000 Km^2 , englobando parte dos estados do Paraná, Santa Catarina e Rio Grande do Sul (BORGES e BORDAS, 1988). Borges e Bordas (1988) distinguiram, nesse planalto, duas zonas homogêneas do ponto de vista físico-climático, considerando critérios de erodibilidade do solo, erosividade da chuva e relevo.

Figura 10 - Localização da bacia hidrográfica do Taboão, no contexto brasileiro e regional



Fonte: autora

A bacia do Taboão pertence à bacia do rio Potiribu, é composta por várias sub-bacias embutidas, monitoradas no Projeto Potiribu, sendo representativa de uma das zonas físico-climáticas homogêneas do derrame basáltico sul-rio-grandense (BORGES e BORDAS, 1988). O monitoramento na bacia é desenvolvido desde 1989 pelo IPH/UFRGS (GIRARDI et al., 2010).

O clima da região é classificado como mesotérmico brando, do tipo temperado, super úmido e sem estação seca (cfa), conforme sistema de classificação Koeppen (NIMER, 1989). Chevallier e Castro (1991) descrevem as precipitações na região como bem distribuídas no ano, sem identificação de um período específico de estiagem, sendo a precipitação média anual em torno de 1700 mm. Matzenauer, Radin e Almeida (2011) relatam níveis médios anuais entre 1800 e 1900 mm para a região de Cruz Alta, com maior média mensal no mês de outubro (em torno de 250 mm) e menor média mensal para os meses de março e agosto (ambos em torno de 140 mm).

A temperatura média do ar varia entre 14°C (mês de maio) e 24°C (mês de janeiro), ocorrendo temperaturas extremas inferiores a 0°C durante o inverno, e superiores a 35°C no período do verão. A amplitude térmica é bastante elevada, sendo a média das temperaturas máximas do mês mais quente igual a 32°C e a média das temperaturas mínimas do mês mais frio em torno de 8°C (IPAGRO, 1989).

A umidade relativa média do ar é 69%, com valor mínimo de 65% (mês de dezembro) e máximo de 80% (mês de julho). A radiação solar é mais intensa no período compreendido entre outubro e março, atingindo valores máximos entre novembro e janeiro. Já a evapotranspiração potencial média está situada entre 2,3 mm/dia (mês de junho) e 4,2 mm/dia (mês de dezembro), com um total anual em torno de 1200 mm (IPAGRO, 1989).

3.2 Caracterização das classes de uso do solo

A bacia do Taboão possui entre 80 e 85% de seu solo ocupado por agricultura extensiva, com predomínio da prática de cultivo “plantio direto”. A soja e o milho configuram os cultivos mais comuns no período do verão, e o trigo e a aveia no inverno (MEDEIROS, 2004; OLIVEIRA, 2006). A utilização do solo para pastagens é menos expressiva do que para a agricultura (VIERO, 2004). Também são encontradas áreas de vegetação nativa (Mata Atlântica) ou em estágio avançado de regeneração, principalmente, na forma de fragmentos de mata ciliar e manchas isoladas de diferentes extensões (raramente alcançando 1 km²)

(GIRARDI et al., 2011). Em alguns pontos da bacia é possível identificar plantios de Araucária (VIERO, 2004).

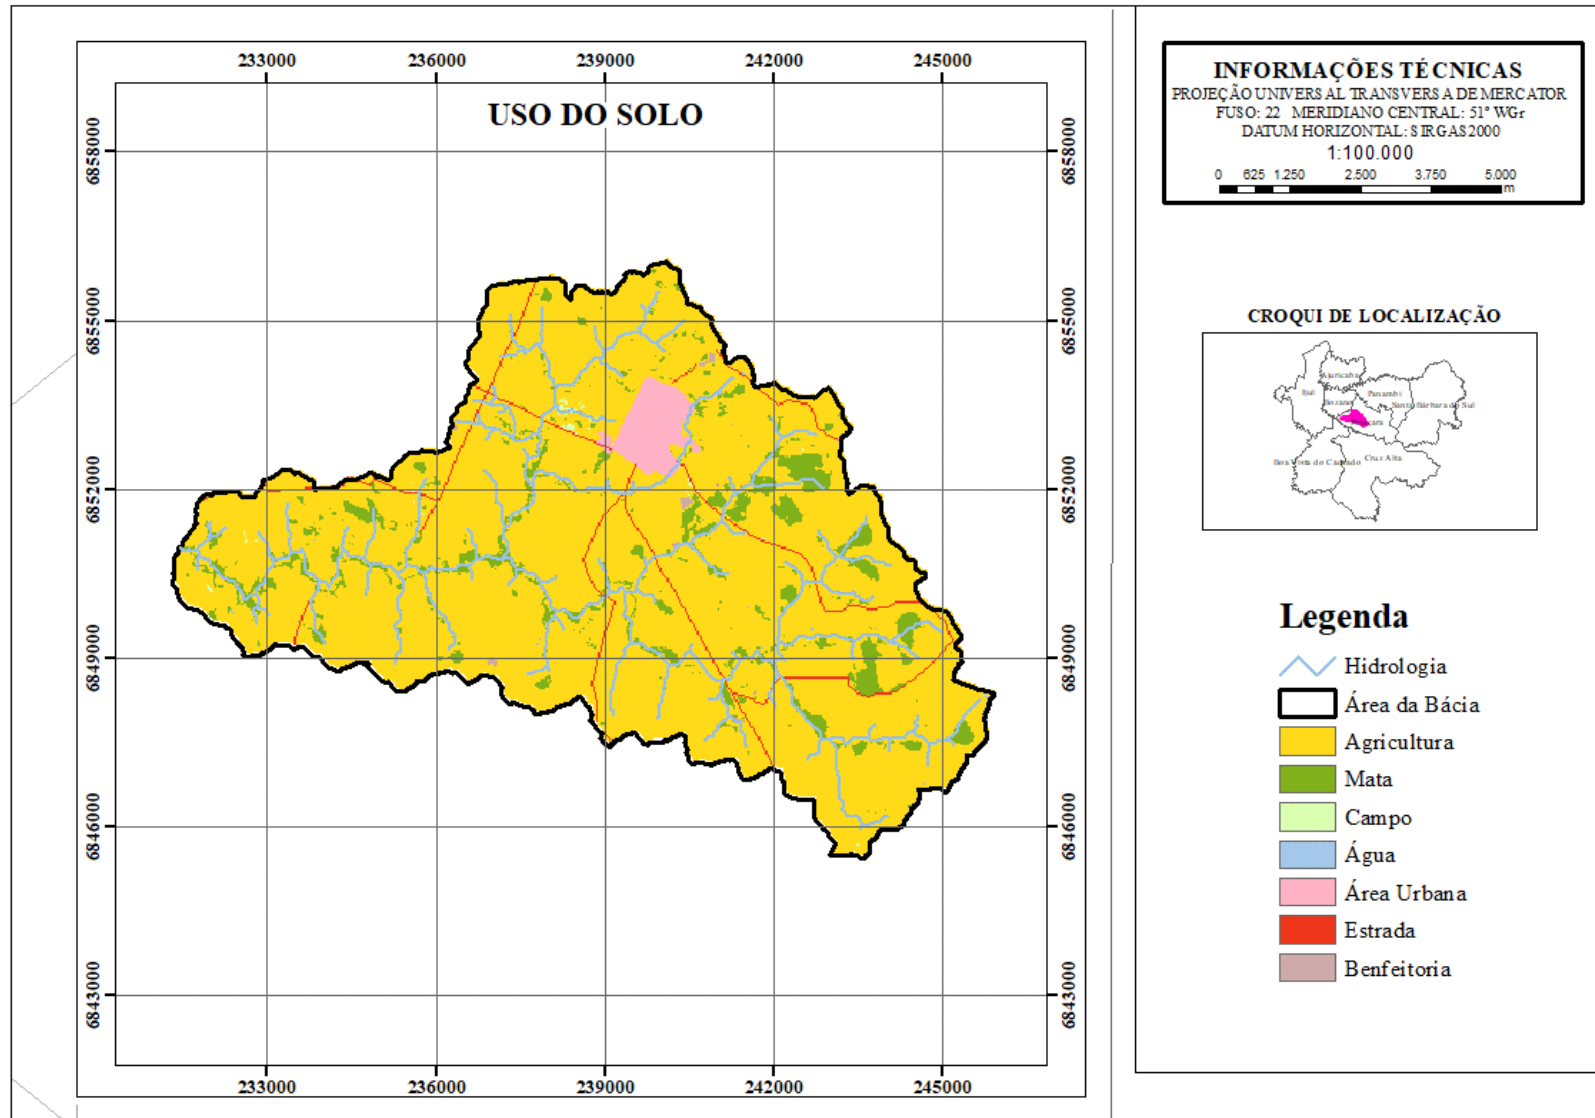
Em geral, a vegetação é composta por resquícios de floresta do tipo intermediário tropical/subtropical, formada por espécies arbóreas, arbustivas e rasteiras, as quais foram sendo destruídas, ao longo dos anos, para dar lugar às lavouras (CARVALHO et al., 1990). Comumente, as pequenas áreas com remanescentes de floresta original são observadas próximas às estradas e aos limites de propriedades. Já as matas galerias encontram-se preservadas nos locais onde os cursos de água são encaixados, mas estão ausentes quando há alargamentos dos talwegues ou ainda, quando existem zonas de alagamento (VIERO, 2004).

A pouca vegetação remanescente é formada por árvores de grande porte, destacando-se: *Peltophorum vogelianum* (canafístola), *Myrocarpus frondosus* (cabriúva), *Cabrlea oblongifolia* (cangerana), *Cedrela fissilis* (cedro), *Patagonula americana* (guajuvira), *Ingá ssp* (ingás), *Cordia frichotoma* (louro), *Enterolobium contortisiliquum* (timbaúva) e *Piptadenia spp* (angico). Todo esse complexo pode estar habitado ainda por epífitas, musgos, líquens e pteridófitas. Entre as espécies que formam a vegetação baixa, destacam-se: *Sorocea ilicifolia* (cincho), *Chusquea spp* (criciúma), *Urera baccifera* (urtigão), *Actinostemon concolor* (laranjeira do mato), *Trichilia elegans* (pau ervilha) e *Genoma schottiana* (urucana) (CARVALHO et al., 1990).

As florestas de galerias são estreitas, densas e de porte medianamente alto, sendo as espécies mais comuns: *Peltophorum dubium* (canafístola), *Lucea divaricata* (açoita cavalo), *Eugenia uniflora* (pitangueira) e *Lithraea brasiliensis* (aroeira preta) (CARVALHO et al., 1990). A vegetação rasteira compreende avencas, gramíneas de baixo e grande porte e cipós rasteiros que, em geral, pertencem à família das bignoniáceas e salpindáceas. Já a vegetação herbácea gramíneo lenhosa distribui-se de forma esparsa e irregular, sendo composta, principalmente, por *Aristida spp* (barba de bode), *Baccharis* (carquejas), *Desmodium spp* e *Trifolium spp* (CARVALHO et al., 1990).

Na Figura 11 é apresentado o mapa dos diferentes usos do solo na bacia do Taboão. Esse mapa foi construído por Depiné (2014), a partir de uma imagem LANDSAT TM (bandas 2, 3 e 4), de 26 de janeiro de 2005, empregando a técnica de Classificação Supervisionada, realizada com auxílio do *software* Idrisi[®]. O mapa apresentado nessa figura passou por um processo de reclassificação das cores para melhor visualização e representação das diferentes classes de uso do solo, seguindo-se a sugestão de cores do Manual Técnico de Uso da Terra (IBGE, 2013).

Figura 11 - Mapa de uso do solo da bacia do Taboão



Fonte: Adaptado de Depiné (2014)

3.3 Caracterização das classes de tipo de solo, variação altimétrica e declividade

Os solos da região foram desenvolvidos a partir de rochas eruptivas basálticas e compreendem aproximadamente 60% da área do planalto basáltico sulino e 7,26% da área territorial do estado do Rio Grande do Sul. A textura deste solo— conforme levantamento do reconhecimento dos solos do Rio Grande do Sul— é caracterizada como argilosa, sendo constituída por 70% de argila, 18% de silte, 7% de areia fina e 5% de areia grossa (BRASIL, 1973).

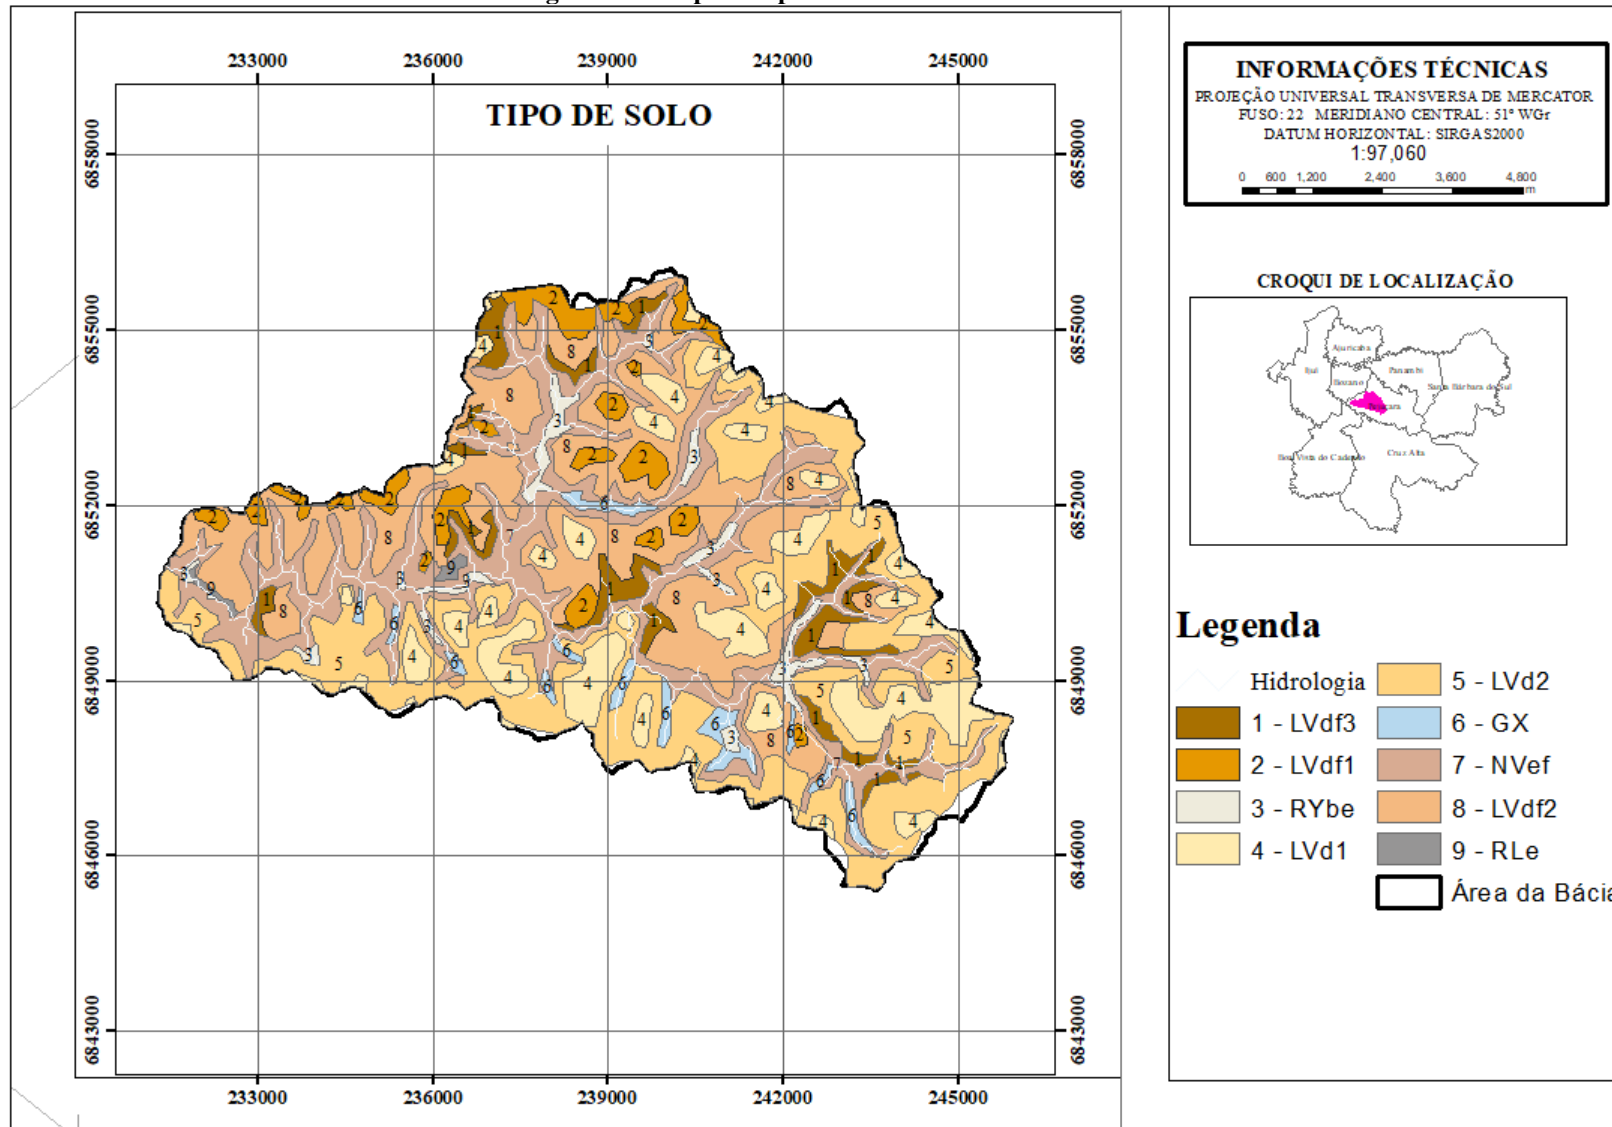
O mapa pedológico foi construído por Carvalho et al. (1990), através de levantamento semidetalhado dos solos presentes na bacia e identificação das unidades de mapeamento, realizado na escala 1:25.000. Esse mapa foi reclassificado, no estudo de Veiro (2004), para adequação ao Sistema Brasileiro de Classificação de Solos de 1999 (EMBRAPA, 1999) e, readequado na pesquisa de Depiné (2014) para a novo Sistema Brasileiro de Classificação de Solos de 2006 (EMBRAPA, 2006).

O enquadramento original foi realizado tendo por base os perfis de solo que descrevem cada unidade de mapeamento, sendo os perfis representados pela descrição morfológica e dados físicos e químicos dos horizontes (CARVALHO et al., 1990), tendo sido identificadas seis unidades de mapeamento no levantamento de solos da região, das quais predominam, conforme classificação atualizada EMBRAPA (2006): Neossolo Flúvico Tb Eutrófico (RYbe), Neossolo Litólico Eutrófico (RLe), Latossolo Vermelho Distrófico (LVd), Latossolo Vermelho Distroférico (LVdf), Nitossolo Vermelho Eutroférico (NVef) e Gleissolo Háptico (GX). Os solos predominantes na bacia são os Latossolos vermelhos, caracterizados por grande profundidade e quantidade de argila (CASTRO, 1996).

Na Figura 12 são mostrados os tipos de solo presentes na bacia do Taboão. O mapa apresentado nessa figura passou por um processo de reclassificação das cores, para melhor visualização e representação dos diferentes tipos de solo.

O Latossolo Vermelho Distroférico apresenta três subclasses na bacia do Taboão (LVdf1, LVdf2 e LVdf3), com base no tipo de relevo e na classe de declividade do terreno onde ocorrem. Esses solos apresentam alta resistência à erosão, quando no estado natural, isso em razão do alto grau de flocculação das argilas, da alta porosidade e da boa permeabilidade, além do fato de ocorrerem em áreas de relevo suave. Entretanto, o uso continuado de maquinário agrícola pesado tem ocasionado a formação de uma camada adensada que dificulta a penetração da água e das raízes, favorecendo os processos erosivos.

Figura 12 - Mapa de tipo de solo da bacia do Taboão



Fonte: Adaptado de Depiné (2004)

O solo da classe LVdf1 (encontrados nas partes mais aplainadas de um relevo suave ondulado) apresenta pequenos riscos de erosão se comparado ao da classe LVdf2 (presentes na metade de áreas de encostas), que possui maior suscetibilidade à erosão, especialmente nos locais onde ocorre uma camada adensada gerada pelo uso contínuo de maquinário pesado; ou ainda, comparado ao solo da classe LVdf3 (encontrado em áreas de declive acentuado, relevo ondulado), que são bem mais susceptíveis à erosão (VIERO, 2004).

O Latossolo Vermelho Distrófico ocorre em relevo suave ondulado, formado por colinas com topos arredondados e vertentes longas; ocupando em torno de 28,5% da área da bacia. Por apresentarem alto grau de floculação, alta porosidade, boa permeabilidade e ocorrerem em relevo favorável, são bastante resistentes à erosão, em seu estado natural. Entretanto, quando sob cultivo, se mal manejados, exibem tendência a desenvolver uma camada adensada que favorece o escoamento superficial da água. Esta unidade de mapeamento foi subdividida em duas subclasses, em função da fase do relevo: LVd1 e LVd2. Os solos da classe LVd2 (presentes em encostas) requerem maiores cuidados em relação à erosão, enquanto que o LVd1 (presente nas partes mais elevadas e aplainadas do relevo) é ligeiramente susceptível aos processos erosivos (VIERO, 2004).

O Nitossolo Vermelho ocorre em 28% da área da bacia do Taboão, nas encostas inferiores das elevações (em geral entre 8 e 15%), próximo aos cursos de água que drenam a região. Apresentam sérios riscos de erosão laminar e concentrada, caso sejam mal manejados, em função dos declives relativamente acentuados em que ocorrem. Já o Gleissolo Háptico compreende os solos comumente encontrados em terrenos baixos e planos, representando 1,2% da área da bacia (VIERO, 2004). Esses solos caracterizam-se pela baixa profundidade e má drenagem (CASTRO, 1996).

O Neossolo Flúvico é um solo que ocorre em áreas com declives entre 1 e 2%, estando presentes em 1,9% da área da bacia. Já o Neossolo Litólico é normalmente encontrado em áreas declivosas (20% ou mais de declive), associado à vegetação tipo floresta subtropical/tropical, ocupando 0,8% da área da bacia (VIERO, 2004).

O modelo numérico do terreno (MNT) foi obtido por Depiné (2004) através de um recorte da cena SH-22-V-C, realizada com o auxílio do *software* ArcGIS (ESRI®), resultando em um mapa de relevo da área da bacia. A cena SH-22-V-C provém de dados de radar, obtidos de sensores no projeto SRTM (*Shuttle Radar Topography Mission*), considerando áreas de 90x90 m. Essa cena foi corrigida e padronizada pela EMBRAPA, para eliminação das falhas, sombras e distorções, resultando em uma imagem, onde cada pixel tem um valor altimétrico

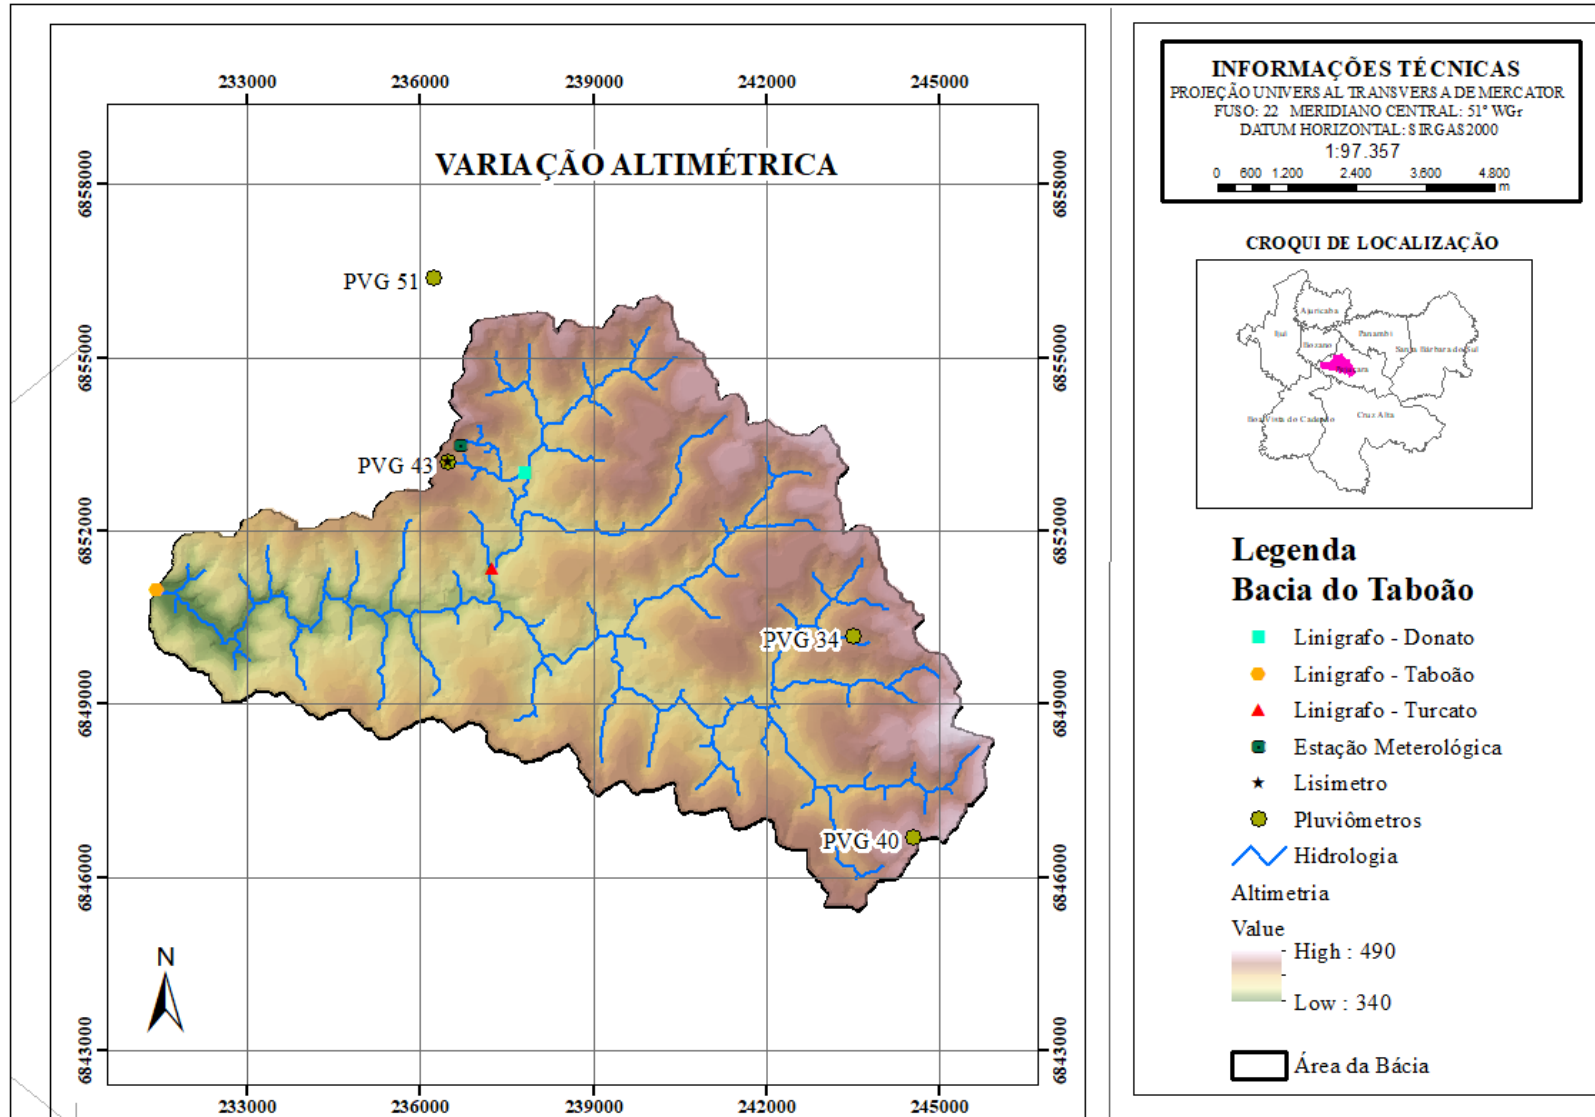
real, visualmente convertido em falsas cores, simbolizando as diversas altitudes (MIRANDA, 2005).

Nessa pesquisa, foi realizada uma reclassificação das cores do MNT original, para melhor visualização. A composição RGB (*Red, Green e Blue*) adotada é uma adaptação do padrão de tabela de cores do USGS (*United States Geological Survey*), onde as cotas mais baixas do terreno apresentam-se em verde escuro e as mais elevadas em tons de rosa. Os valores intermediários distribuem-se em tons de verde, amarelo, marrom e rosa, seguindo o aumento da elevação (MIRANDA, 2005). Na Figura 13 é apresentado o mapa reclassificado da variação da altimetria na bacia do Taboão.

A bacia do Taboão possui uma forma alongada, com eixo principal orientado na direção Noroeste. Sua amplitude de relevo varia de 340 a 485 m, sendo que as altitudes mais elevadas se concentram no extremo leste da bacia.

A declividade média na bacia é de 8%, embora, nos vales, as declividades variem entre 10 e 20%. Localmente, o arroio Taboão e seu tributário (arroio Rincão) apresentam vales entalhados na rocha, especialmente na região sudoeste da bacia. Estas são as áreas mais declivosas da bacia, podendo as vertentes apresentar declividades em torno de 30%, chegando a atingir 45% em alguns pontos (VIERO, 2004).

Figura 13 - Mapa da variação da altimetria na bacia do Taboão

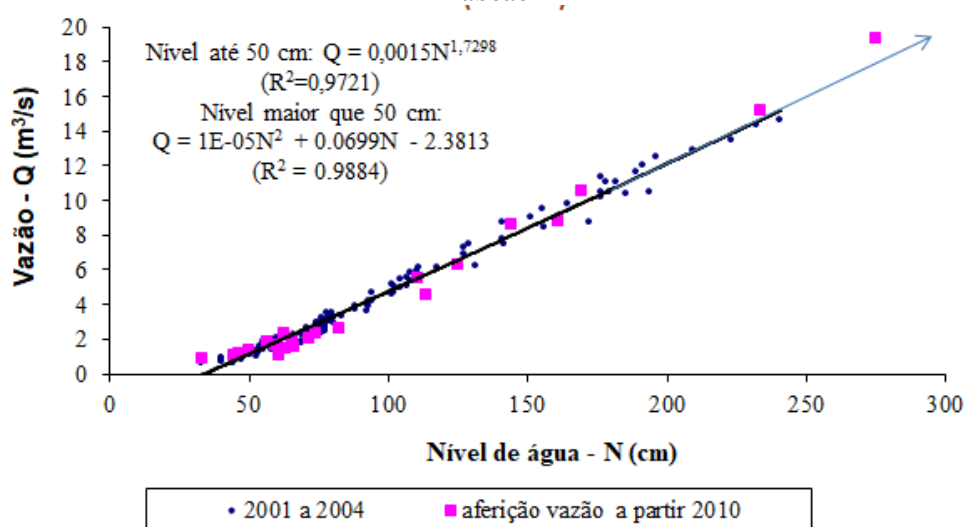


Fonte: Adaptado de Viero (2004)

3.4 Monitoramento do nível de água e determinação da vazão

O monitoramento da variação do nível de água no rio foi realizado no exutório da bacia do Taboão (coordenadas: 231507E m e 6851032N m, Fuso 22J), por meio de um linígrafo com sensor boia (OTT Thalimedes com Data logger embutido), que registra o nível de água a cada 10 min. Os valores medidos foram convertidos em vazão por meio de uma curva-chave (Figura 14) desenvolvida pela equipe do IPH (Projeto Potiribu).

Figura 14 - Curva-chave para determinação da vazão em função da variação do nível de água, na bacia do Taboão



Fonte: curva elaborada pela equipe do Projeto Potiribu a partir de monitoramentos realizados *in situ*, para o período compreendido entre 2001 e 2010 (inclusive)

Foram realizadas medições fluviométricas periódicas (geralmente mensais) para analisar possíveis alterações dessa curva, decorrentes de mudanças da seção de monitoramento. Essas medições foram efetuadas com emprego do *Acoustic Doppler Current Profiler* (ADCP S5, da Sontek), que possibilita a verificação da vazão em lâminas de água compreendidas entre 30 cm e 6 m.

Os dados de vazão utilizados na pesquisa, para calibração e verificação dos processos hidrossedimentológicos no modelo SWAT foram obtidos pelo cálculo das médias diárias e mensais, estimadas a partir das leituras de nível de 10 min e da equação da curva-chave proposta para a bacia.

3.5 Monitoramento da turbidez

O monitoramento da turbidez foi necessário para a determinação das séries contínuas de CSS, utilizadas no processo de calibração e de verificação do modelo SWAT para simulação da produção de sedimentos na bacia.

Esse monitoramento foi realizado por meio de um sensor de turbidez DTS-12 SDI Turbidity Sensor (Figura 15), da empresa Forest Technology System, LTD. Tal sensor baseia-se em princípios ópticos, com ângulo de detecção da luz incidente a 90°, sendo classificado como um sensor óptico-nefelométrico, com comprimento de onda da energia incidente igual a 780 nm e capacidade de identificação da luz dispersa na direção frontal e para trás. O alcance médio de medição desse sensor encontra-se entre zero e 1600 NTU, com resolução de 0,01 NTU; sendo a acurácia para a faixa entre zero e 399,99 NTU de 2% e de 4% para a faixa entre 400 e 1600 NTU (FTS, 2013).

Figura 15 - Sensor de turbidez (DTS-12 SDI Turbidity Sensor) e no detalhe a superfície óptica e a lâmina de limpeza



Fonte: autora

O sensor realiza 100 leituras de turbidez, ao longo de cinco segundos e, em seguida, calcula, exibe e registra a média, a variância, a mediana e os valores máximos e mínimos da turbidez, no intervalo de tempo desejado; além dos valores de temperatura da água. Esse sensor também possui uma lâmina de silicone, que ajuda a minimizar as incrustações biológicas, possibilitando a limpeza da sonda, antes do início das leituras, quando programada para tal

(FTS, 2013). Os dados interpretados pela sonda foram armazenados em um logger modelo H500 XL, produzido pela empresa Design Analysis Associates INC.

O sensor foi instalado no exutório da bacia no dia 18 de fevereiro de 2013, mas começou a apresentar problemas operacionais e em julho de 2013 foi retirado de campo e enviado ao fabricante; sendo reinstalado em dezembro de 2013. O turbidímetro foi programado para armazenar as leituras a cada 10 min, sempre com a limpeza da sonda alguns segundos antes. No ano de 2016 o turbidímetro voltou a apresentar problemas operacionais, impossibilitando a utilização dos dados relativos a esse período para determinação da CSS.

3.6 Concentração de sedimentos suspensos (CSS)

No período compreendido entre junho de 2013 e outubro de 2015 foram realizadas 17 coletas mensais da mistura água-sedimento, utilizando instrumentos da série DH. Além disso, foram monitorados cinco eventos de cheia, em que foram coletadas 42 amostras da mistura água-sedimento para diferentes níveis de água, totalizando 59 níveis amostrados (coletas em eventos de cheia e rotina).

Para as coletas da mistura água-sedimento, a seção transversal do rio, que tem aproximadamente entre 5 e 11 m de largura (dependendo da cota rio), foi dividida em 10 verticais, utilizando-se o método de IIL (EDWARDS e GLISSON, 1999) e coleta por integração na vertical. Nas coletas realizadas com o nível do rio abaixo de 1 metro utilizou-se o equipamento DH-48 a vau. Para as coletas com o nível acima de 1 metro, utilizou-se o equipamento DH-59, com um sistema teleférico composto de cabos de aço, roldanas e guincho que sustentam o equipamento durante as coletas (Figura 16).

Foram coletadas amostras da mistura água-sedimento em cinco verticais bem distribuídas, escolhendo-se as pares ou as ímpares, totalizando cinco amostras em cada um dos níveis monitorados durante os eventos de cheia. Tais amostras foram enviadas ao laboratório de sedimentos do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul (IPH/UFRGS), sendo a CSS de cada amostra determinada por métodos de filtração. A CSS média de cada nível foi estimada como a média das cinco CSS monitoradas para aquele nível.

Para as coletas de rotina realizadas com o nível do rio abaixo de 1 metro, as cinco amostras coletadas nas verticais analisadas foram misturadas em um balde fracionador, retirando-se três amostras para estimativa da CSS em laboratório.

Figura 16 - Sistema de guincho instalado na bacia do Taboão para coleta de amostras água-sedimento e monitoramento da vazão



Fonte: autora (arquivo pessoal)

Nesse caso, a CSS para o nível de água foi considerada como sendo a média das três amostras coletadas. O menor número de amostras nas coletas de rotina deve-se a uniformidade do transporte de sedimentos, ao longo da seção, na ausência de ocorrência de evento de cheia.

Essas informações de CSS levantadas foram utilizadas para definição de modelos de RNAs para estimativa de séries contínuas de CSS, as quais foram empregadas, posteriormente, juntamente com dados de nível de água e de turbidez, para o cálculo da produção de sedimento diária, mensal e anual na bacia do Taboão.

Os níveis de água e a turbidez, associados aos 59 valores de CSS monitorados, foram calculados pela média dos valores instantâneos registrados pelo Linígrafo e Turbidímetro, respectivamente, considerando-se para esse cálculo o horário de início e fim de cada amostra da mistura água-sedimento coletada.

3.7 Modelos de RNAs para preenchimento de falhas nos dados de nível de água⁶

As falhas nos dados de nível de água monitorados no período de 2011 a 2016 foram preenchidas por meio de Modelos de Combinações de Redes Neurais Artificiais (CRNAs)⁷, com entradas baseadas em informações de precipitação média e; de dados de nível de água monitorados nas bacias adjacentes/embutidas à bacia do Taboão. Além desse período, foram também desenvolvidos modelos para preenchimento das falhas no ano de 2010.

Os modelos de CRNAs constituem um conjunto de recursos, programados em Matlab[®] R2010a, para a seleção de forma automática de uma RNA, entre um conjunto existente de redes, em função da disponibilidade de dados de entrada e sua utilização. O número de RNAs que podem ser disponibilizadas para uso posterior é dado pelo número de combinações possíveis de entradas disponíveis ($2^n - 1$ combinações).

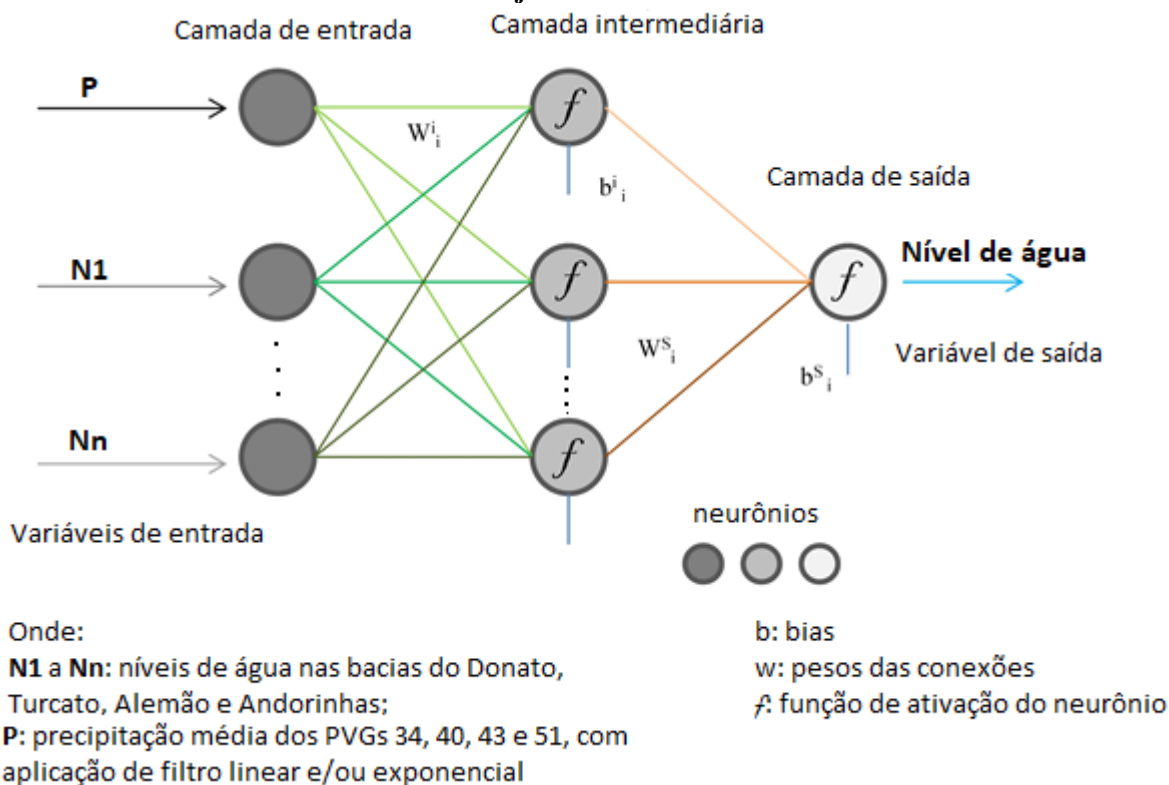
A ideia básica do modelo de CRNA é a constituição de uma estrutura hiperdimensional de células, onde cada uma das combinações possíveis constitui um endereço de memória, no qual é armazenada uma RNA (Figura 17), correspondente a esta combinação.

⁶ Texto construído com base no artigo:

PEDROLLO, O.C.; CASTRO, N.M dos R.; SARI, V., AMARAL, S. Estimate of water level and turbidity data from monitored data of precipitation and water level, using artificial neural networks. Artigo em elaboração para submissão.

⁷ Os recursos e as rotinas utilizadas para construção desses modelos foram, originalmente, desenvolvidos pelo prof Dr Olavo Correa Pedrollo, docente-pesquisador do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul (IPH/UFRGS).

Figura 17 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados de nível de água na bacia do Taboão, utilizando dados de precipitação média e de nível de água em bacias embutidas ou adjacente à bacia do Taboão



As entradas disponíveis para as combinações foram: i) as informações da média móvel do nível de água (10 em 10 minutos) nos exutórios das quatro bacias embutidas e/ou adjacente à bacia do Taboão (anteriores ao exutório: bacia do Donato, Turcato e Alemão e; posterior ao exutório: bacia do Andorinhas); ii) as informações de média móvel, com aplicação de filtro linear, do nível de água no exutório das bacias do Donato, Turcato e Alemão; iii) a média da chuva de 10 minutos dos quatro pluviógrafos usados nessa pesquisa (PVGs 34, 40, 43 e 51) e; vi) a média móvel ponderada exponencialmente de precipitações antecedentes com intervalos de 10 minutos.

Como a relação entre os níveis nos exutórios dessas bacias não ocorre de forma direta, ou seja, os níveis que ocorrem no tempo “t” na bacia do Taboão não estão diretamente correlacionados àqueles ocorridos para o mesmo tempo nos exutórios das demais bacias; procurou-se identificar a relação de defasagem entre os níveis de água no exutório do Taboão e nos exutórios das bacias adjacentes/embutidas. Para isso, analisou-se a correlação entre as médias móveis dos níveis (sem aplicação de filtro linear) para as bacias do Donato, Turcato, Alemão e Andorinhas em relação à bacia do Taboão, buscando-se definir a defasagem adequada

entre os dados. A mesma análise foi realizada entre a chuva média e o nível de água na bacia do Taboão, procurando-se determinar a defasagem mais satisfatória entre essas duas variáveis.

Essa diferença entre os tempos de ocorrência dos níveis/precipitações deve-se ao tempo de resposta da bacia à determinada precipitação, e às características do processo de escoamento das águas nos canais, de montante para jusante. Dessa forma, o tempo de defasagem ou tempo de resposta indicaria a estimativa do tempo necessário para que um evento que ocorre a montante de uma bacia ocorra à sua jusante.

Para as entradas consideradas nesse estudo, identificou-se uma defasagem de 31, 24 e 21 intervalos de tempo de 10 minutos nas bacias do Donato, Turcato e Alemão, respectivamente, quando se aplicou os dados de nível de água (sem aplicação de filtro linear) e; de 54 intervalos de tempo para as informações de precipitação média (sem aplicação de filtro exponencial). Na bacia do rio Andorinhas não foi realizado procedimento de defasagem dos dados de nível de água.

Uma vez que o nível de água depende, primeiramente, das precipitações, e sendo seu valor mais influenciado pelas chuvas mais recentes, um índice representativo das condições aproximadas pode ser obtido por meio da série de precipitações. Moore (1980), por exemplo, utilizou a média móvel das chuvas passadas, ponderada exponencialmente (EWMA), definida pela equação 20:

$$EWMA_t = (1 - \alpha)EWMA_{t-1} + \alpha.P_t \quad (20)$$

Onde: P_t representa as chuvas ocorridas no tempo t ; α é o coeficiente de ponderação.

Para um intervalo temporal unitário, o coeficiente α está relacionado à meia-vida h através da equação 21:

$$\alpha = 1 - 0,5^{(1/h)} \quad (21)$$

A opção de escolha pela meia-vida de um dado intervalo de tempo significa que a precipitação que é reduzida à metade para a composição de EWMA corresponde a um intervalo atrás. Da mesma forma, se a meia-vida é de dois intervalos de tempo, isso significa que as precipitações reduzidas à metade para a composição de EWMA são as de um e dois intervalos atrás (contribuição conjunta). Essa média móvel tem sido aplicada em séries temporais com intervalos constantes, como um filtro temporal, de acordo com a equação 20.

Dessa forma, além de considerar como variável de entrada a chuva média (com a adequada defasagem), considerou-se também a média móvel das chuvas passadas com ponderação exponencial (filtro exponencial aplicado aos dados já defasados), de maneira que os valores da chuva mais recente tenham um peso maior do que os valores de chuvas mais

antigos. Esse procedimento foi utilizado por Oliveira, Pedrollo e Castro (2011), com ótimo resultado, para a bacia do rio Ijuí (NS=0,95), da qual a bacia do Taboão é uma sub-bacia. Os autores identificaram que a média móvel, quando aplicada como variável de entrada, resultava em melhor eficiência no modelo comparativamente às chuvas isoladas acumuladas.

Para o desenvolvimento do modelo de CRNA foram elaborados um conjunto de recursos para o armazenamento, a verificação das redes disponíveis e; para realizar a busca de uma RNA específica do modelo de CRNA, em função das entradas disponíveis em cada registro. Tais entradas disponíveis são informadas por meio de um código, constituído por um vetor de dígitos binários, com um dígito para cada entrada do modelo, onde o “1” corresponde à disponibilidade do dado de entrada e o “2” à sua indisponibilidade.

Portanto, a execução do modelo completo para a realização do preenchimento é automática, pois o recurso de execução verifica, para cada registro, quais são as variáveis de entrada disponíveis, e busca, no modelo de CRNA, qual a rede neural correspondente, para então, aplicá-la, gerando o dado de saída preenchido.

O procedimento metodológico utilizado para o desenvolvimento de cada uma das RNAs do modelo de CRNA baseou-se na divisão dos dados disponíveis em três séries para treinamento, validação cruzada e verificação da rede. As entradas de cada modelo de RNA variaram conforme as diferentes possibilidades de dados disponíveis.

Na divisão da série total disponível em série de treinamento, de validação e de verificação, testou-se diferentes opções de tamanho da amostra para treinamento da rede, usando-se o restante dos dados para a validação e a verificação das RNAs. Os dados foram selecionados por meio de amostragem sistemática, que possibilita a seleção de amostras solicitadas e a identificação das amostras residuais da seleção, ambas sem falhas, na série correspondente de registros.

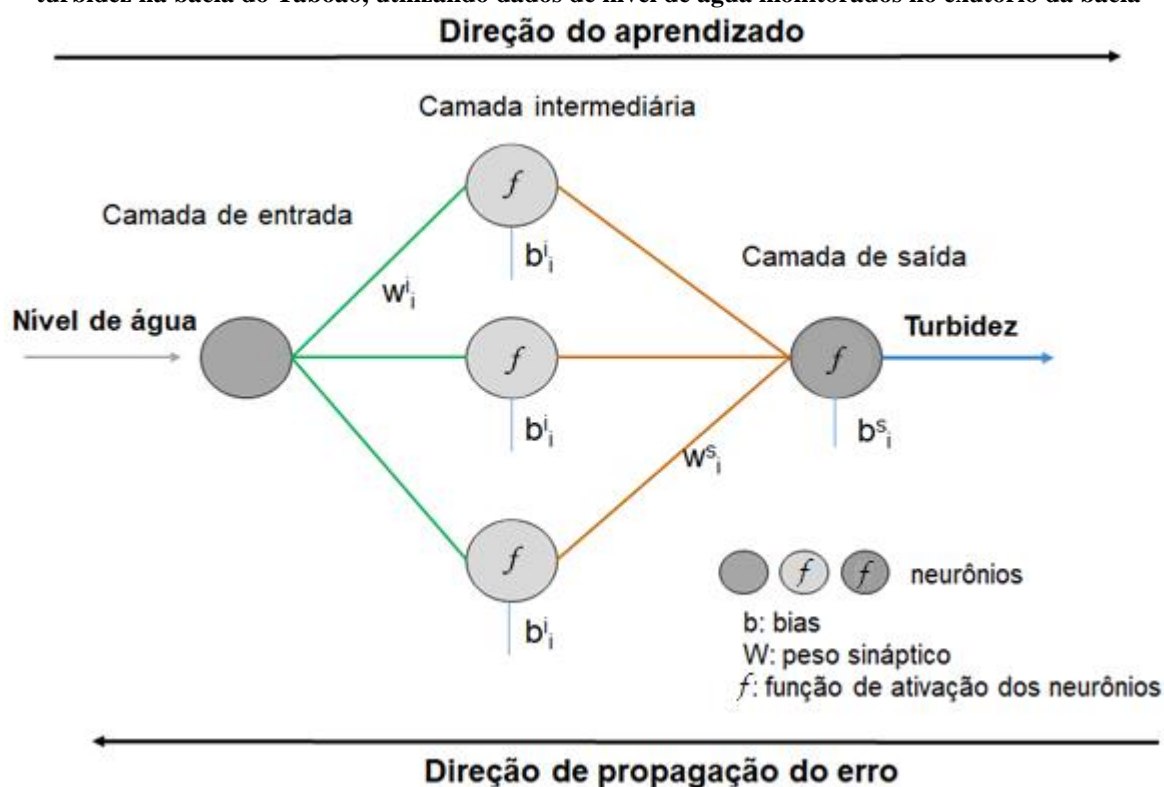
A quantidade de dados a ser utilizada para a série de treinamento pode ser variada, podendo a amostragem ser realizada para: i) produzir na seleção e na amostragem residual, a mesma distribuição da série original ou; ii) reduzir as maiores frequências, em favor de valores mais altos do domínio, resultando uma distribuição mais equilibrada da amostragem selecionada, que pode ser mais representativa também de setores menos favorecidos do domínio (dados em menor quantidade na amostra original), sem penalizar, no entanto, a distribuição da amostragem residual; ou seja, possibilita uma distribuição mais uniforme desses valores extremos nas séries. Além disso, nessa amostragem, é possível forçar ou não a inclusão dos extremos de cada uma das variáveis na amostragem selecionada.

Os critérios considerados para o treinamento das RNAs foram: $2n+1$ neurônios na camada interna, onde “n” representa o número de entradas empregadas na rede em desenvolvimento; número máximo de 300.000 ou de 500.000 ciclos e; 3 repetições iniciais. As estatísticas empregadas para análise dos desempenhos das RNAs estão descritas no subitem 3.9.4.

3.8 Modelos de RNAs para preenchimento de falhas nas informações de turbidez⁸

As falhas nos dados monitorados de turbidez, entre os anos de 2013 a 2015, foram preenchidas por meio de um modelo de RNA, que tem por base informações de nível de água medidas (sem defasagem ou filtro), de 10 em 10 minutos, no exutório da bacia do Taboão (Figura 18).

Figura 18 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados de turbidez na bacia do Taboão, utilizando dados de nível de água monitorados no exutório da bacia



Fonte: autora

⁸ Texto construído com base no artigo:

PEDROLLO, O.C.; CASTRO, N.M dos R.; SARI, V., AMARAL, S. Estimate of water level and turbidity data from monitored data of precipitation and water level, using artificial neural networks. Artigo em elaboração para submissão.

O período total de dados disponível (2013 a 2015), totalizando 108.044 registros, foi dividido em partes, com desenvolvimento de RNAs distintas para cada uma dessas subparcelas. Cada uma das partes compôs-se, portanto, de um determinado período de tempo da amostra de dados disponível (2013 a 2015).

Foram testadas diferentes divisões da amostra total (4, 5, 6, 8, 10 e 20 partes), buscando a melhoria das estatísticas de desempenho dos modelos de RNAs e também, a melhor representatividade do período representado naquela partição, assegurando resultados mais adequados no posterior preenchimento das falhas do período abrangido em cada uma dessas partições.

No desenvolvimento das RNAs para cada uma das partes da amostra total, cada parte foi subdividida em três séries, uma para treinamento, uma para validação cruzada e outra para verificação da RNA. Nessa divisão foram testadas, ainda, diferentes configurações para a quantidade de dados utilizados na série de treinamento da rede (500, 800, 1000, 1500 e 2000 registros), sendo os dados restantes empregados para a validação cruzada e a verificação da RNA treinada.

Para a seleção dos dados para o treinamento, a validação e a verificação de cada RNA, na série correspondente de registros (cada parte da subdivisão inicial), empregou-se o método de amostragem sistemática do domínio (semelhante ao descrito no item 3.7), com seleção das amostras para treinamento e identificação das amostras residuais para as etapas de validação e de verificação da rede, ambas sem falhas. Foram considerados para o treinamento de cada RNA: três neurônios na camada interna ($2n+1$, onde “n” representa o número de entradas); número máximo de ciclos igual a 500.000 e; 3 repetições iniciais. As estatísticas empregadas para análise do desempenho das redes desenvolvidas estão descritas no subitem 3.9.4.

3.9 Modelos de RNAs e funções explícitas para previsão da CSS

Foram desenvolvidos dois tipos de modelos para a estimativa das séries contínuas de CSS: i) modelos baseados em funções explícitas, comumente empregadas para determinação da CSS e; ii) modelos de estimativa da CSS tendo por base RNAs.

3.9.1 Subdivisão dos dados amostrais

Nas aplicações realizadas para definição dos modelos de RNAs para estimativa da CSS, os dados foram previamente distribuídos em dois conjuntos principais, ou seja, um conjunto

total de treinamento e outro de verificação. Esse procedimento foi realizado, porque as RNAs precisam ser verificadas, após o treinamento, com amostras que não participaram deste processo.

Para as aplicações dos modelos com funções explícitas, para efeito de comparação com os modelos de RNAs desenvolvidos, utilizou-se o mesmo procedimento e a mesma subdivisão dos registros amostrais.

Uma vez que os modelos com RNAs não servem para a generalização fora do domínio do treinamento, é necessário que a amostra total de treinamento seja abrangente desse domínio. Portanto, tomou-se o cuidado de, na distribuição dos registros, alocar os que apresentaram dados extremos, máximos ou mínimos, no conjunto total de treinamento da rede.

O método utilizado para a distribuição dos registros nesses conjuntos consistiu-se de: identificação de registros extremos (máximos e mínimos de cada variável, seja de entrada, seja de saída); ordenamento dos demais registros, em ordem de grandeza da variável de saída, e separação, por amostragem sistemática, de 24 registros (ou seja, um pouco mais de 1/3 do total disponível) para a amostragem de verificação, resultando 35 registros para a composição da amostragem total de treinamento da rede.

3.9.2 Modelos de funções explícitas

Para efetuar, posteriormente, a comparação com os modelos de RNAs a serem desenvolvidos, foram preliminarmente ajustadas funções explícitas, lineares, linearizáveis e não-linearizáveis, das relações entre CSS, turbidez e nível de água.

Nessa pesquisa, utilizou-se o método quase-Newton BFGS para a procura dos parâmetros das funções experimentadas, mesmo para aquelas equações com formulação linear, uma vez que se desejava efetuar comparações e porque algumas das fórmulas somente poderiam ser ajustadas por técnicas iterativas.

Como não se desejava experimentar uma nova técnica para os modelos formulados por funções explícitas foi utilizada para a procura dos parâmetros que minimizam a função objetivo, a função `fminunc` existente no Matlab[®] R2010a, a qual implementa o método BFGS. A função objetivo adotada foi a média dos quadrados dos erros, e as condições de finalização foram o número máximo de iterações e as variações máximas da função objetivo e dos parâmetros entre iterações sucessivas.

Na determinação das funções lineares e linearizáveis aproximadas, inicialmente definiram-se as equações mais comuns empregadas para estimativa da CSS, utilizando-se como

variáveis de entrada isoladas os níveis de água e a turbidez. Adicionalmente, procurou-se uma função (linearizável ou não-linearizável) que conjugasse os efeitos das funções anteriores, para aproveitar as informações das duas variáveis de entrada (nível de água e turbidez); uma vez que cada uma delas pode fornecer contribuições adicionais na determinação da CSS, não presentes no comportamento da outra variável. E também para que fosse possível a comparação do desempenho desses modelos de duas variáveis com o modelo de RNA proposto.

As equações testadas para ajuste entre a CSS e as variáveis de entrada nível de água e turbidez foram do tipo linear, potencial, exponencial e polinomial, além de combinações entre essas funções. Essas equações compreendem as relações mais utilizadas para determinação da CSS a partir dessas variáveis de entrada analisadas (FINLAYSON, 1985; OLD et al., 2003; MINELLA et al., 2008; NAVRATIL et al., 2011; POLETTO et al., 2011; RAJAE 2011; RAJAE et al., 2011; TENA et al.; 2011; ABE et al., 2012; BAYRAM, KANKAL e ÖNSOY, 2012; BUSCHMAN et al., 2012; CHIKITA et al., 2012; KISI, 2012; MARTTILA e KLOVE, 2012; PEREIRA, PAIVA e PAIVA, 2012; MUHAMMADI, AKBARI e AZIZZIAN, 2012; SHIRI e KISI 2012; BOUKHRISSA et al., 2013; GHORBANI et al., 2013; HARRINGTON e HARRINGTON; 2013; LIU et al., 2013; PINHEIRO et al., 2013; BAYRAM et al., 2014; HAIMANN et al., 2014; SLAETS et al., 2014; ZIEGLER et al., 2014; OLYAIE et al., 2015).

Para o ajuste dessas funções utilizou-se a mesma série empregada no treinamento dos modelos de RNAs, sendo a eficiência das relações determinadas analisadas a partir do emprego da mesma série usada para a verificação das redes. A adoção de divisão semelhante da série de dados foi efetuada para que os modelos de RNAs e as funções explícitas pudessem ser comparados em igualdade de condições; uma vez que, para as RNAs, a divisão da série de dados é indispensável para prevenir o superajustamento da rede.

3.9.3 Modelos baseados em RNAs⁹

Nesse estudo foram utilizados programas escritos pelos autores, em código do Matlab[®] R2010a, para desenvolvimento dos recursos para o treinamento e a verificação das RNAs.

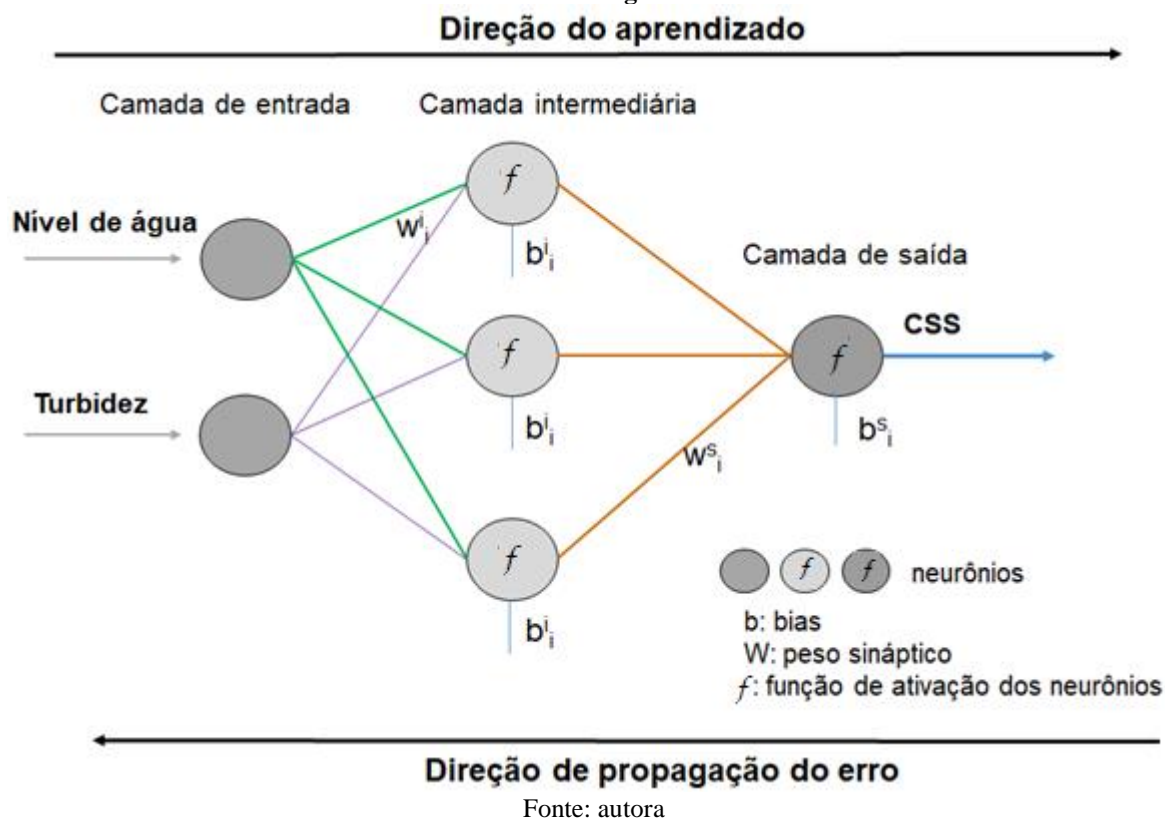
Foram consideradas como variáveis de entrada o nível de água e a turbidez, e como saída a CSS (Figura 19). Essas variáveis configuram-se entre as entradas mais utilizadas em estudos

⁹ Texto construído com base no artigo:

SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017. <https://doi.org/10.1007/s11269-017-1785-4>.

internacionais para previsões sedimentológicas, que tiveram por base modelos de RNAs (ver estudos descritos no APÊNDICE A).

Figura 19 - Esquema representativo da RNA desenvolvida para estimativa da CSS na bacia do Taboão, utilizando dados de turbidez e de nível de água monitorados no exutório da bacia



Os recursos necessários foram programados no ambiente do *software*, em detrimento do uso de outros já existentes neste ambiente, pois a experimentação de novos procedimentos fez-se necessária, para além do algoritmo retropropagativo básico de treinamento (apresentado por RUMELHART, HINTON e WILLIAMS, 1986) utilizado juntamente com técnicas de aceleração do treinamento (VOGL et al., 1988), e outros recursos, como a amostragem sistemática.

Devido ao pequeno número de dados disponíveis para o treinamento e para a verificação (apenas 59 valores de CSS), não foi possível utilizar a técnica da validação cruzada, tradicionalmente executada para evitar o superajustamento da rede; na medida em que era inviável dividir uma amostra tão reduzida em três partes, para o treinamento, a validação e a verificação da RNA. Por essa razão foi elaborado um método alternativo para o treinamento e a verificação dos modelos de RNAs desenvolvidos. Técnica semelhante foi aplicada para o treinamento dos modelos de preenchimento das falhas de precipitação.

A essência desse método, chamado de “Método de Validação por Reamostragem” (SARI et al., 2017), é a procura—mesmo com relativamente poucos registros disponíveis para a pesquisa— da complexidade mínima da rede (número de neurônios na camada interna), que, sendo progressivamente simplificada a partir de uma rede superdimensionada, ainda não apresente redução da capacidade de generalização, por deficiência de graus de liberdade, em relação à rede inicial. Porém, isso implica em três condições a serem consideradas: i) o método deve ser praticável mesmo quando não existem amostras suficientes para a divisão em três conjuntos, de treinamento, validação e verificação, como é exigido pelo método da validação cruzada; ii) os testes decisivos de desempenho devem ser realizados com amostras de verificação, que não participaram do algoritmo de treinamento; iii) os efeitos de superajustamento devem ter sido evitados, restando apenas insuficiência de graus de liberdade como causa de menor capacidade de aproximação.

A primeira e a segunda condição foram atendidas pela divisão da amostra total disponível em apenas dois conjuntos (o conjunto total de amostras de treinamento e o conjunto de amostras de verificação) e pelo uso da técnica da reamostragem para a validação, aplicada ao total dos registros de treinamento. Neste método, a reamostragem consistiu no uso de “n” partições do número total N de registros de treinamento, de forma que cada um de “n” treinamentos foi realizado, alternadamente, com “n-1” das partições, e o restante foi utilizado como amostra de validação. O total dos “n” treinamentos constituiu um experimento de teste de uma alternativa de complexidade, cujo resultado foi o conjunto de N saídas da rede neural, proporcionando N erros para o cálculo da estatística decisiva do experimento. A utilização da reamostragem, para compor o conjunto de dados para a validação, possibilitou o ajuste e a verificação do modelo com quantidade relativamente reduzida de registros de dados.

A terceira condição pode ser atendida pela adoção de uma condição de finalização do treinamento, utilizada para conter o superajustamento, e resultante de pesquisa preliminar. Esta pesquisa preliminar (etapa 1) consistiu na experimentação, com avaliação do desempenho com as amostras de validação (também nesta etapa, amostras resultantes do uso da técnica de reamostragem do número total de registros de treinamento), com uma rede neural inicial (propositalmente superdimensionada), de cada valor decrescente da condição de finalização (máximo admitido, no treinamento, para o erro absoluto médio). O valor desta condição a partir da qual o erro absoluto médio na validação começa a aumentar foi, então, adotado como critério para a pesquisa da complexidade (etapa 2), uma vez que este foi considerado o limite para a interrupção do treinamento, para que não ocorresse superajustamento na etapa 1.

A pesquisa da complexidade (etapa 2), que consiste na pesquisa do número de neurônios na camada intermediária foi, então, executada por tentativas (com a condição de finalização conhecida, resultante da pesquisa anterior), a partir da configuração utilizada na etapa 1, com a redução progressiva, a cada experimento, do número de neurônios na camada interna, até que a capacidade de aproximação do modelo sofreu redução (em relação ao modelo inicial, mais complexo, obtido da etapa 1), na amostra de validação. Admitindo-se que a condição de finalização pela aproximação admitida da função no treinamento é adequada para evitar o superajustamento, que o número máximo de ciclos admitido é mais do que suficiente para que, com graus de liberdade suficiente, ocorra o treinamento, e que certo número de repetições é realizado para contornar a possibilidade de um mau começo aleatório do procedimento de treinamento, a redução da capacidade de generalização, quando ocorre, pode ser considerada devido à insuficiência de complexidade da rede neural.

O número de registros deslocados, alternadamente, da amostra de treinamento, para formar o conjunto de validação, dependeu do número de registros restantes, sendo, entretanto, suficiente para cada treinamento sucessivo. Recomenda-se, com base na experiência e testes realizados, mesmo em casos com menos dados, pelo menos 30 registros a cada procedimento com o algoritmo de treinamento, e que a composição de cada conjunto a ser sucessivamente utilizado para a validação seja definida por meio de amostragem sistemática, ou seja, por ordenamento dos registros segundo a variável de saída e posterior seleção com base em um fator de repetição igual ao número “n” de conjuntos, de forma a resultarem conjuntos de distribuição aproximadamente igual dos dados de saída.

Posteriormente, após as pesquisas realizadas, o treinamento final da RNA foi executado com o uso da condição de finalização (resultante da etapa 1), e com o número de neurônios para a camada interna obtido na etapa 2, usando-se toda a amostra de treinamento, portanto, sem a técnica da reamostragem.

Tanto as pesquisas da condição de finalização e da complexidade, quanto o treinamento do modelo final, foram realizadas com repetições de cada experimento de treinamento, para contornar os efeitos da inicialização aleatória, conferindo maior robustez ao método. Adotou-se, em todos os procedimentos, a alternativa que apresentou, entre as repetições realizadas, a mediana das estatísticas de desempenho com a amostragem de decisão, uma vez que esta é representativa dos treinamentos realizados e é menos afetada por resultados extremos do treinamento do que seria, por exemplo, a repetição que resultou na estatística de desempenho mais próxima da média destas entre as obtidas no conjunto das repetições realizadas.

Dessa forma, nos procedimentos de pesquisa que requerem validação por reamostragem, adota-se a condição de finalização ou a complexidade do modelo cuja estatística de desempenho correspondeu à mediana, entre as estatísticas de desempenho das repetições realizadas, com o total de registros de validação, ao final de cada experimento. Do mesmo modo, no treinamento final do modelo, adota-se o treinamento cuja estatística de desempenho correspondeu à mediana, entre as estatísticas de desempenho das repetições, na aplicação com o total de registros de treinamento, também porque os treinamentos mais bem-sucedidos ainda podem, em alguma medida, estar afetados por superajustamento.

O algoritmo básico para a pesquisa da condição de finalização (etapa 1) pode ser descrito pelo texto estruturado:

Informações fornecidas:

Conjunto total de registros de dados disponibilizados para treinamento.

Vetor com os valores das condições de finalização a serem testadas.

Número de neurônios na camada interna e funções de ativação da rede.

Número máximo de ciclos e número de repetições dos procedimentos.

Definição do número de conjuntos de validação e do número de registros de cada conjunto, com a condição de, a cada reamostragem, restarem pelo menos 30 registros para o treinamento.

Para cada valor do vetor de condições de finalização, faça:

Para cada repetição, faça:

Para cada um dos conjuntos de validação, faça:

Execução do algoritmo de treinamento, com os registros restantes.

Cálculo dos resultados do modelo, com o conjunto de validação, e armazenamento dos erros correspondentes.

Fim dos conjuntos de validação.

Cálculo da estatística de validação para a amostragem total de validação.

Fim das repetições.

Identificação, com base na estatística de validação, da repetição que correspondeu à mediana das estatísticas de desempenho, e armazenamento da estatística de validação correspondente.

Fim dos testes da condição de validação.

Seleção da condição de finalização que resultou na rede com maior aproximação no treinamento, antes de ter início redução de desempenho na validação pelo efeito do superajustamento devido ao excesso de treinamento.

Da mesma forma, o algoritmo para a pesquisa da complexidade (etapa 2) pode ser descrito pelo texto estruturado:

Informações fornecidas:

Conjunto total de registros de dados disponibilizados para treinamento.

Condição de finalização obtida na etapa anterior.

Número máximo a ser pesquisado de neurônios na camada interna e funções de ativação da rede.

Número máximo de ciclos e número de repetições dos procedimentos.

Definição do número de conjuntos de validação e do número de registros de cada conjunto, com a condição de, a cada reamostragem, restarem pelo menos 30 registros para o treinamento.

Para cada valor do número de neurônios, em ordem decrescente, faça:

Para cada repetição, faça:

Para cada um dos conjuntos de validação, faça:

Execução do algoritmo de treinamento, com os registros restantes.

Cálculo dos resultados do modelo, com o conjunto de validação, e armazenamento dos erros correspondentes.

Fim dos conjuntos de validação.

Cálculo da estatística de validação para a amostragem total de validação.

Fim das repetições.

Identificação, com base na estatística de validação, da repetição que correspondeu à mediana das estatísticas de desempenho, e armazenamento da estatística de validação correspondente.

Fim dos testes da complexidade.

Seleção do número de neurônios na camada interna que resultou na rede que, com menor complexidade, ainda não sofreu redução de desempenho devido à insuficiência de graus de liberdade.

A condição de finalização obtida na etapa 1 (máximo erro absoluto médio admitido no treinamento) foi entrada para a execução da etapa 2, de pesquisa da complexidade (número ideal de neurônios na camada interna). Embora o objetivo da pesquisa seja a obtenção do modelo resultante da etapa 2 (nomeado nessa pesquisa por Modelo_2), também foi gerado o modelo intermediário, com superdimensionamento da complexidade, ao final da etapa 1, chamado Modelo_1, apenas com a finalidade de verificar se o modelo definitivo (Modelo_2) realmente resultou sem perda de capacidade de aproximação da função, em relação ao modelo superdimensionado, conforme a proposta do método.

A avaliação final da eficiência do método proposto para a construção do modelo com RNA foi efetuada com base na análise da capacidade de generalização deste modelo resultante, pelo desempenho observado, segundo as estatísticas utilizadas, na aplicação ao conjunto de registros de verificação, que não participou, em nenhuma etapa, do processo de definição da configuração ou do treinamento da rede neural.

Alternativamente, a mesma metodologia foi empregada para desenvolver dois outros modelos para estimativa da CSS, utilizando como entrada: i) somente dados de nível de água, sendo tal modelo possível de ser empregado nas situações em que ocorram falhas nos dados de turbidez registrados e; ii) somente dados de turbidez, sendo tal modelo possível de ser utilizado quando os dados de nível de água estão ausentes.

Para comprovar a ocorrência de superajustamento e a necessidade do método proposto para evitá-lo, inicialmente foi definido e treinado um modelo RNA, com treinamento pelo algoritmo retropropagativo, sem emprego de validação cruzada ou de outro método para prevenir o superajustamento (chamado nessa pesquisa de Modelo_0), já que não haviam dados suficientes para tais análises.

3.9.4 Estatísticas de desempenho dos modelos

As estatísticas utilizadas para verificação do desempenho dos modelos, baseadas principalmente no erro na saída da rede ou Ea (equação 22), foram o erro absoluto médio ou EaM (equação 23), o erro absoluto máximo ou Ea(Max) (equação 24), o erro absoluto mediano ou Ea(50) (percentil 50% do Ea), o erro absoluto não ultrapassado com frequência 95% ou Ea(95) (percentil 95% do Ea), a raiz da média dos quadrados dos erros ou RMSE (equação 25) e o coeficiente de Nash-Sutcliffe (NASH e SUTCLIFFE, 1970) ou NS (equação 26).

$$Ea = CSS_{c_i} - CSS_{o_i} \quad (22)$$

$$EaM = \frac{1}{N} \sum_{i=1}^N |CSS_{o_i} - CSS_{c_i}| \quad (23)$$

$$Ea(\text{Max}) = \text{máximo}(Ea) \quad (24)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (CSS_{o_i} - CSS_{c_i})^2} \quad (25)$$

$$NS = 1 - \frac{\sum_{i=1}^N (CSS_{o_i} - CSS_{c_i})^2}{\sum_{i=1}^N (CSS_{o_i} - \overline{CSS}_o)^2} \quad (26)$$

Onde: CSS_{o_i} é a concentração de sedimentos suspensos observada, CSS_{c_i} é a concentração de sedimentos suspensos calculada pela RNA, N é o número de dados utilizados e \overline{CSS}_o é a concentração de sedimentos suspensos média observada no monitoramento.

Com o EaM procura-se quantificar, em termos médios, as diferenças entre os valores reais e os valores estimados, sendo que o modelo com o menor EaM é considerado de “melhor

desempenho”. O $Ea(95)$ representa o valor em que o erro não é ultrapassado em 95% dos valores calculados, ou seja, apenas 5% desses valores apresentarão erros superiores ao $Ea(95)$. Esta estatística é mais robusta do que o erro máximo, que pode ser afetado por erros ocasionados por valores atípicos na amostra.

O NS é uma medida da proporção da variância dos dados que é explicada pelo modelo, representando a capacidade de ajuste da RNA, podendo variar de $-\infty$ até 1, quando então consegue aproximar perfeitamente a função ajustada.

3.10 Erosividade da chuva e produção de sedimentos diária, mensal e anual

A erosividade da chuva foi calculada pelo índice EI30, definido como sendo o índice de erosividade das chuvas, calculado em função da multiplicação da energia cinética da chuva pela intensidade máxima da chuva ocorrida em 30 minutos consecutivos. Considera-se que esse índice representa, adequadamente, o efeito erosivo do impacto da gota de chuva e da enxurrada (WISCHMEIER e SMITH, 1978).

Para estimativa da erosividade foram utilizados os dados de precipitação originais monitorados na bacia, sem qualquer preenchimento. O índice de erosividade foi calculado para as chuvas do pluviógrafo PVG 40, já que esse PVG apresentava menor percentual de falhas preenchidas nos anos analisados (14%, 0,63% e 1,04% para os anos de 2013, 2014 e 2015, respectivamente). Os demais pluviógrafos empregados nessa pesquisa possuíam percentual de falhas mais elevados, variando entre 14,5 e 27% para o PVG 34, de 15 a 44% para o PVG 43 e; de 8 a quase 100% para o PVG 51. Os cálculos foram realizados com utilização do *software* Hydraccess[®], utilizando as equações propostas por Wischmeier e Smith (1965, 1978).

Para essa análise, foram considerados diferentes critérios para a separação dos eventos de chuva, em função de: i) a *intensidade mínima da chuva* (considerados: 0, 5 ou 10 mm); ii) o *intervalo de tempo* original dos registros (10 minutos) e; iii) o *total mínimo de cada chuva* (considerados: 0, 5, 10 ou 20 mm). Cada valor de erosividade foi nomeado em função desses três critérios. Assim sendo, por exemplo, para a intensidade mínima de 5 mm, com registros de 10 minutos e total mínimo de cada chuva considerado igual a 5 mm, a erosividade foi identificada como: “*Erosividade 5-10-5*”.

A produção de sedimentos diária, mensal e anual, utilizada para a calibração e a verificação do modelo SWAT, foi determinada a partir das séries contínuas da CSS média para um intervalo de 10 min (calculadas pelos modelos de RNAs, utilizando informações de turbidez

e de nível de água), e pelos dados contínuos de vazão média de 10 min (Q) (estimados por meio da curva-chave da bacia, empregando os níveis monitorados a cada 10 min).

As falhas nos dados de turbidez e de nível de água monitorados foram preenchidas, previamente, utilizando modelos de RNAs desenvolvidos nessa pesquisa, conforme procedimentos descritos nos itens 3.7 e 3.8.

O valor diário da produção de sedimentos (PS_{dia}) foi calculado pela integração do produto $Q \times CSS$ de todas as leituras de 10 min de um dado dia, sendo a vazão utilizada em L/s e a CSS em g/L. Como Q representa a média dos valores de vazão (em m^3/s) e a CSS a concentração média de sedimentos suspensos (em g/L), ambas para um intervalo de 10 min, o produto $Q \times CSS$ resulta na PS (em gramas), produzida a cada segundo do intervalo de 10 min ($PS_{1\text{seg}}$). Logo, o valor da PS para todo o intervalo de 10 min ($PS_{10\text{min}}$) foi calculado pela multiplicação da $PS_{1\text{seg}}$, produzida a cada segundo, pelo número de segundos existentes no intervalo de 10 min (ou seja: 600 s).

Por fim, a produção diária de sedimentos (PS_{dia}) foi obtida pela soma de todas as $PS_{10\text{min}}$, produzidas a cada 10 min do dia, totalizando 144 valores (ou 144 intervalos de 10 min) somados em um dia. Já a PS mensal ($PS_{\text{mês}}$) foi obtida pela soma dos valores diários da produção de sedimentos (PS_{dia}) de um dado mês e; a produção de sedimentos anual (PS_{ano}) foi estimada pelo somatório da $PS_{\text{mês}}$ de cada um dos 12 meses do ano.

3.11 Simulação hidrossedimentológica com o modelo SWAT

A simulação dos processo hidrossedimentológicos por meio do modelo SWAT requer dados geográficos e cartográficos (planos de informação: mapas de uso do solo, de tipo de solo e MNT), dados tabulares (séries temporais de precipitação, temperatura máxima e mínima do ar, radiação solar, umidade relativa do ar e velocidade do vento), além de outras entradas diretas no modelo (parâmetros relacionados aos solos, ao ciclo hidrológico, ao escoamento superficial e aos processos de erosão e produção de sedimentos, etc.).

Para as simulações realizadas nessa pesquisa foram considerados: i) cálculo do escoamento superficial pelo método de infiltração de Green & Ampt (GREEN e AMPT, 1911) modificado por Mein e Larson (1973), já utilizado na pesquisa realizada por Depiné (2014); ii) cálculo da evapotranspiração pelo método de Penman-Monteith (MONTEITH, 1965), metodologia mais indicada quando se dispõem de informações diárias de radiação solar, temperatura do ar, umidade relativa do ar e velocidade do vento (TUCCI, 2005); iii) propagação

da água pelos canais pelo Método da Acumulação Variada (WILLIAMS, 1969), empregado por Depiné (2014), com bons resultados, para a simulação da vazão na bacia do Taboão e; iv) equação de Bagnold (BAGNOLD, 1977; WILLIAMS, 1980) para cálculo do transporte de sedimentos, degradação e deposição no canal. A erosão do solo e a produção de sedimentos na paisagem, calculada pelo modelo SWAT, emprega a MUSLE.

As principais equações utilizadas nas rotinas do modelo SWAT para estimativa dos processos hidrossedimentológicos estão descritas no ANEXO A. Informações mais detalhadas acerca desses processos e dos parâmetros de entrada do modelo podem ser encontradas em Neitsch et al. (2002, 2005, 2010, 2011) e Arnold et al. (2012a).

3.11.1 Planos de informação requeridos pelo modelo SWAT: mapas de uso do solo, tipo de solo, modelo numérico do terreno e classes de declividade

A obtenção dos mapas de uso do solo, de tipo de solo e o MNT da bacia, além dos critérios para definição das classes de declividade foram descritos nos itens 3.2 e 3.3. Os mapas utilizados para as simulações foram apresentados nas Figuras 11 a 13.

Na Tabela 11 são apresentadas as classes e nomenclaturas utilizadas no modelo SWAT para a classificação do uso do solo na bacia do Taboão.

Tabela 11 - Classes utilizadas no modelo SWAT para a classificação do uso do solo presente na bacia do Taboão

Nomenclatura para modelagem	Classes de uso e ocupação do solo	Área (%)
AGRL	agricultura genérica – cultivo anual	88,22
FRSE	floresta perene	7,75
PAST	pastagem	0,19
WATR	água	0,06
URHD	área residencial de alta densidade	2,32
URLD	área residencial de baixa densidade	0,30
UTRN	estradas	1,33

Fonte: autora

Para tornar a simulação mais condizente com o uso do solo e as práticas agrícolas realizadas na bacia, procederam-se algumas modificações nas operações de manejo pré-definidas no banco do modelo SWAT, para os diferentes usos do solo.

Nas HRUs com uso do solo caracterizado como mata (FRSE) foi habilitada a opção de desenvolvimento inicial das plantas (*Initial Plant Growth*), objetivando indicar a ocorrência de uso da terra já em crescimento na HRU no início da simulação. Através dessa opção, os ciclos

de manejo anuais pré-definidos deixam de ser executados e as condições iniciais definidas pelo usuário são mantidas durante o período simulado. Para tal, o código de *status* do uso da terra (parâmetro IGRO) foi alterado, de modo a indicar a presença de uso da terra em crescimento (IGRO=1), assumindo-se um índice de área foliar inicial igual a 6 (LAI_INIT=6 m²/m²) para a vegetação.

O mesmo procedimento foi aplicado para as HRUs com uso do solo do tipo pastagem, utilizando-se índice de área foliar inicial com valor 3 (LAI_INIT=3 m²/m²).

Nas HRUs com culturas genéricas (AGRL) buscou-se representar o sistema de sucessão de culturas, usualmente praticado na bacia, com adoção de plantio de uma cultura de inverno (trigo) nos meses mais frios e; uma cultura de verão (soja) no período mais quente. Desse modo, foi estipulado o plantio de soja (SOY), em 07 de novembro (operação: *Plant/begin growing season*), com realização da colheita em 28 de abril (*Harvest and kill*). A sucessão com a cultura de inverno (trigo) foi simulada com a adição de um novo plantio em 05 de junho (*Plant/begin growing season*), e colheita em 29 de outubro (*Harvest and kill*).

Na Tabela 12 são descritas as classes e nomenclaturas utilizadas no modelo SWAT para a classificação dos tipos de solos presentes na bacia do Taboão.

Tabela 12 - Classes utilizadas no modelo SWAT para a classificação do tipo de solo presente na bacia do Taboão

Classe de solo	Descrição do tipo de solo	Área (%)
LVd1	Latossolo Vermelho Distrófico típico	10,63
LVd2	Latossolo Vermelho Distrófico	24,44
LVdf1	Latossolo Vermelho Distroférrico típico	4,72
LVdf2	Latossolo Vermelho Distroférrico	24,85
LVdf3	Latossolo Vermelho Distroférrico típico, A moderado	5,33
NVef	Nitossolo Vermelho Eutroférrico	24,70
RYbe	Neossolos Flúvicos Tb Eutróficos	2,55
GX	Gleissolo Háptico	2,42
RLe	Neossolo Litólico Eutrófico	0,35

Fonte: autora

Na simulação com o modelo SWAT, o relevo da bacia do Taboão foi subdividido em cinco classes de declividade, tendo por base o MNT (variação atimétrica apresentada na Figura 13), considerando-se os limites de: i) classe 1: de 0 até 5%, ii) classe 2: acima de 5 até 8%, iii) classe 3: acima de 8 até 20%, iv) classe 4: acima de 20 até 45% e; v) classe 5: acima de 45%

3.11.2 Características físico-hídricas do solo requeridas pelo modelo SWAT

Na Tabela 13 são apresentados os valores dos parâmetros de entrada do modelo SWAT, relacionados às características físico-hídricas, para as diferentes classes de solo presentes na bacia do Taboão. Esses valores foram utilizados por Depiné (2014) para a simulação dos processos hidrológicos na bacia, sendo também empregados nessa pesquisa para simulação dos processos hidrossedimentológicos.

Entre tais características estão: os grupos de saturação (HYDGRP), a profundidade de raiz (SOL_ZMX), a porosidade (ANION_EXCL), a profundidade da camada (SOL_Z), a densidade aparente (SOL_BD), a capacidade de água no solo (SOL_AWC), a condutividade hidráulica saturada (SOL_K), a erodibilidade (USLE_K), o albedo (SOL_ALB), o carbono orgânico (SOL_CBN), e as porcentagens de argila, silte, areia e pedras.

Os valores desses parâmetros foram obtidos por Depiné (2014) através de ensaios práticos, de descrições encontradas na literatura e também, pela calibração dos parâmetros do modelo SWAT. A seguir apresenta-se breve descrição, extraída de Depiné (2014), acerca da obtenção de cada um desses parâmetros.

Os dados de profundidade da raiz (SOL_ZMX) e de profundidade da camada (SOL_Z) foram adaptados de Viero (2004). A condutividade hidráulica saturada (SOL_K) foi determinada através de ensaio de infiltração com infiltrômetros de anéis concêntricos, considerando os diferentes tipos de solo presentes na bacia (DEPINÉ, 2014).

A densidade aparente (SOL_BD) foi determinada pela relação entre a massa de solo seco e o volume da amostra, a partir de coletas de solo indeformado realizadas em 26 pontos da bacia (distribuídos nos diferentes tipos de solo), em triplicata, sendo a densidade de cada ponto obtida pela mediana das triplicatas.

Também foram analisadas, a partir dessas coletas, a porosidade e as características granulométricas e texturais do solo. As porcentagens de areia, silte, argila e pedras foram classificadas de acordo com NBR 7181/84 (ABNT, 1984) em cascalho (> 2 mm), areia (2 a 0,05 mm), silte (0,05 a 0,002 mm) e argila (<0,002 mm). A porosidade (ANION_EXCL) foi estimada através da relação da densidade do solo com a densidade das partículas do solo (DEPINÉ, 2014).

Os ensaios para determinação da porosidade, granulometria, densidade e água retida no solo (SOL_AWC) foram realizados no Laboratório de Sedimentos do IPH/UFRGS, seguindo as recomendações descritas em EMBRAPA (1997). O valor de albedo do solo (SOL_ALB) foi

determinado tendo por base os trabalhos de Lopes e Valeriano (2007) e Silva e Valeriano (2003) (DEPINÉ, 2014).

Tabela 13 - Características físico-hídricas das classes de solo presentes na bacia do Taboão

Classes	LVd1	LVd2	LVdf1	LVdf2	LVdf3	Nref	Rybe	GX	RE
nlayers	4	4	4	4	4	3	4	4	4
hydgrp	A	A	B	B	B	B	B	B	B
sol_zmx	3000	3000	3500	3500	3500	3500	3500	3000	3000
anion_excl	0,3	0,38	0,38	0,38	0,5	0,32	0,37	0,5	0,33
sol_z1	250	250	300	300	300	300	250	180	230
sol_bd1	1,6	1,64	1,62	1,71	1,31	1,73	1,28	1,52	1,37
sol_awc1	0,56	0,6	0,92	0,67	0,97	0,4	0,73	0,85	1,4
sol_k1	285	195	161	65	41	265	101	145	161
sol_cbn1	0,8	1,08	1,31	2,26	1,72	1,3	1,7	2,35	1,7
clay1	54,6	51,3	59,2	43,5	60,5	59,9	47,3	44,8	35
silt1	12,7	15,3	23,3	2,7	21	21,4	24,4	22,5	12
sand1	31,6	33,4	17,5	33,8	18,5	18,7	28	32,7	48
rock1	1,1	0	0	0	0	0	0,3	0	5
sol_alb1	0,15	0,15	0,15	0,13	0,23	0,18	0,16	0,16	0,16
usle_k1	0,0991	0,0967	0,1129	0,1091	0,1045	0,1057	0,1097	0,1082	0,1049
sol_ec1	0	0	0	0	0	0	1	0	1
sol_z2	700	700	1000	1000	1000	900	1000	600	1000
sol_bd2	1,41	1,5	1,52	1,63	1,29	1,62	1,27	1,47	1,55
sol_awc2	0,86	0,8	0,92	0,67	0,95	0,6	0,75	0,6	1,2
sol_k2	260	202	100	50	40	126	48	69	31
sol_cbn2	1,13	1,18	1	1,55	1,3	0,68	1,43	0,54	0,54
clay2	55,3	64,9	70	65	56	70,2	57,7	47,3	46,5
silt2	12,2	11	14,7	16	23	16,4	24,5	22,6	12,7
sand2	32,5	24,1	15,3	18,5	21	13,3	16,8	29,8	30,8
rock2	0	0	0	0,5	0	0,1	1	2,2	10
sol_alb2	0,15	0,15	0,15	0,13	0,23	0,15	0,16	0,16	0,16
usle_k2	0,0995	0,1055	0,1212	0,1106	0,1176	0,1246	0,1108	0,1389	0,1223
sol_ec2	0	0	0	0	0	0	0	0	0
sol_z3	1500	1500	2000	2000	2000	3500	2000	1500	2000
sol_bd3	1,51	1,47	1,52	1,5	1,29	1,49	1,19	1,37	1,75
sol_awc3	0,56	0,7	1,05	0,84	0,88	0,6	0,35	0,61	1,4
sol_k3	190	150	77	30	19	143	0,45	78	31
sol_cbn3	0,95	0,72	0,54	0,95	1,08	0,4	1,43	0,27	1,3
clay3	57,3	68,1	72,3	48,9	56,6	78	57,2	54,4	37,6
silt3	9,9	11,9	16,5	29,6	22,4	12	21,3	18,9	17,1
sand3	32,5	20	11,2	21,5	21	10	21,5	26,7	35,3
rock3	0,3	0	0	0	0	0	0	0	10
sol_alb3	0,15	0,15	0,15	0,13	0,23	0,15	0,16	0,16	0,16
usle_k3	0,0979	0,1117	0,1351	0,147	0,1258	0,1252	0,1146	0,1332	0,1349
sol_ec3	0	0	0	0	0	0	0	0	0
sol_z4	3000	3000	3500	3500	3500		3500	3000	3000
sol_bd4	1,4	1,37	1,7	1,47	1,28		1,19	1,37	1,4
sol_awc4	0,5	0,75	1,05	0,94	0,93		0,35	0,61	1,4
sol_k4	80	159	87	34	21		0,45	78	31
sol_cbn4	0,4	0,54	0,45	0,63	0,86		1,43	0,27	0,54
clay4	57,6	68	71,4	48,5	56,6		57,2	54,4	37,6
silt4	9,9	12	15,7	29,6	22,4		21,3	17,9	17,1
sand4	32,5	20	11,2	21,9	21		21,5	27,7	35,3
rock4	0	0	1,7	0	0		0	0	10
sol_alb4	0,15	0,15	0,15	0,13	0,23		0,16	0,16	0,16
usle_k4	0	0	0	0	0		0	0	0
sol_ec4	0	0	0	0	0		0	0	0

NLAYERS: número de camadas, HYDGRP: grupos de saturação (A, B, C ou D), SOL_ZMX: profundidade máxima da raiz (mm), ANION_EXCL: porosidade, SOL_Z: profundidade da camada de solo (mm), SOL_BD: densidade aparente (mg/m³ ou g/cm³), SOL_AWC: capacidade de água no solo, SOL_K: condutividade hidráulica saturada (mm/h), SOL_ALB: albedo, SOL_CBN: carbono orgânico (%), USLE_K: erodibilidade [(0,013ton/m²/hr)/(m³/ton/cm)], CLAY: porcentagem de argila (%), SILT: porcentagem de silte (%), SAND: porcentagem de areia (%) e ROCK: porcentagem de pedras (%)

Fonte: Adaptada de Depiné (2014)

3.11.3 Precipitação e demais parâmetros relacionados a essa variável, requeridos para simulação do modelo SWAT

Para a simulação do modelo SWAT com o método de infiltração de Green & Ampt são necessárias informações subsidiárias de precipitação. Além disso, são também requeridos os parâmetros: média mensal da precipitação total; desvio padrão para a precipitação diária do mês; coeficiente de assimetria para a precipitação diária por mês; probabilidade de dias úmidos seguidos de dias secos para o mês; probabilidade de dias úmidos seguidos de dias úmidos para o mês; média mensal de dias de precipitação no mês e; valor máximo de 0,5 h de chuva em todo o período de registros do mês.

As informações pluviométricas horárias utilizadas nesse estudo foram obtidas a partir de quatro pluviômetros (PVGs 34, 40, 43 e 51), tipo báscula (Marca Davis) e de uma estação climatológica automática (PVG 13), instalados na área da bacia. A localização desses pontos de monitoramento foi apresentada na Figura 10.

Na Tabela 14 são mostradas as coordenadas de localização e a altitude dos pluviômetros e da estação climatológica.

Tabela 14 - Coordenadas de localização e altitude dos pluviômetro e da estação climatológica

Pluviômetro	Latitude Sul (graus)	Longitude Oeste (graus)	Altitude (m)
PVG 34	-28,457	-53,605	470
PVG 40	-28,481	-53,609	470
PVG 43	-28,420	-53,689	440
PVG 51	-28,393	-53,692	470
Estação climatológica (PVG 13)	-28,418	53,687	440

Fonte: autora

Para a determinação dos parâmetros médios mensais requeridos pelo SWAT (média mensal da precipitação total; desvio padrão para a precipitação diária do mês; coeficiente de assimetria para a precipitação diária por mês; probabilidade de dias úmidos seguidos de dias secos para o mês; probabilidade de dias úmidos seguidos de dias úmidos para o mês; média mensal de dias de precipitação no mês e; valor máximo de 0,5 h de chuva em todo o período de registros do mês), foram considerados os registros diários de precipitação da série histórica compreendida entre 01/09/1989 e 31/12/2016. Esses parâmetros foram calculados conforme descrição e equações apresentadas em Neitsch et al. (2005, 2010, 2011).

O valor máximo de chuva em 30 minutos (0,5 h), necessário para obtenção do parâmetro RAINHMX, foi obtido por método indireto, através dos dados horários de precipitação,

utilizando a tabela de “coeficientes de desagregação de chuvas”. Esta prática é comumente empregada para estabelecer relações de intensidade-duração-frequência (BERTONI e TUCCI, 2012).

Na Tabela 15 são apresentados os coeficientes de desagregação das chuvas, propostos pela CETESB (1980) para todo o território nacional. Desse modo, a chuva máxima de 30 minutos corresponde a 74% da chuva total verificada 1 h. O parâmetro RAINHHMX foi então calculado a partir desse coeficiente aplicado aos dados horários de precipitação.

Tabela 15 - Coeficientes de desagregação de chuvas de 24 horas de duração

Duração	Coeficientes	Duração	Coeficientes
1 dia/24 h	1,14	30 min/1 h	0,74
12 h/24 h	0,85	25 min/30 min	0,91
10 h/24 h	0,82	20 min/30 min	0,81
8 h/24 h	0,78	15 min/30 min	0,70
6 h/24 h	0,72	10 min/30 min	0,54
1 h/24 h	0,42	5 min/30 min	0,34

Fonte: CETESB (1980)

Na Tabela 16 são descritos os dados médios mensais requeridos pelo modelo SWAT para as informações relacionadas à precipitação.

Tabela 16 - Dados médios mensais utilizados no modelo SWAT

Mês	PCPMM	PCPSTD	PCPD	PR_W1	PR_W2	PCPSKW	RAINHHMX
Janeiro	152,513	72,466	21,694	0,382	0,816	1,142	31,684
Fevereiro	111,318	63,027	21,380	0,318	0,831	2,417	24,495
Março	115,529	45,722	21,713	0,315	0,800	0,679	25,518
Abril	132,403	47,542	20,259	0,358	0,774	0,351	30,947
Mai	135,401	74,503	22,843	0,322	0,825	2,120	41,116
Junho	133,914	47,505	22,120	0,362	0,814	-0,078	29,084
Julho	134,065	33,754	21,917	0,314	0,768	0,194	30,537
Agosto	100,262	47,729	20,278	0,324	0,735	0,532	28,714
Setembro	142,222	62,394	20,080	0,396	0,726	0,591	33,844
Outubro	201,379	74,119	20,929	0,383	0,776	2,013	36,888
Novembro	124,910	60,362	18,375	0,309	0,695	1,088	28,061
Dezembro	142,470	58,068	20,375	0,429	0,728	0,820	34,323

Onde: PCPMM: média mensal da precipitação total (mm); PCPSTD: desvio padrão para a precipitação diária do mês (mm); PCPSKW: coeficiente de assimetria para a precipitação diária por mês; PR_W1: probabilidade de dias úmidos seguidos de dias secos para o mês; PR_W2: probabilidade de dias úmidos seguidos de dias úmidos para o mês; PCPD: média mensal de dias de precipitação no mês (dias) e; RAINHHMX: valor máximo de 0,5 h de chuva em todo o período de registros do mês (mm)

Fonte: autora

3.11.3.1 Preenchimento de falhas nos dados horários de precipitação¹⁰

As falhas nos dados horários de precipitação, para o período de 2011 a 2016, foram preenchidas utilizando-se uma nova metodologia, empregando modelos de CRNAs, conjugados com o uso de médias e; utilizando como entrada, dados de chuva obtidos de pluviógrafos vizinhos ao posto a ser preenchido.

Como os postos vizinhos, que são usados como entrada no modelo para o preenchimento também estão sujeitos a falhas, os modelos de CRNAs desenvolvidos constituíram-se de uma RNA (Figura 20) para cada combinação possível de entradas de postos vizinhos (PVGs) com dados disponíveis. Porém, como algumas situações podem apresentar melhores resultados de preenchimento com o uso das médias dos postos vizinhos no lugar do emprego dos modelos de RNAs, na aplicação do modelo final para o preenchimento de falhas, foi verificado, automaticamente, para cada registro, a situação de disponibilidade de dados nos postos vizinhos, realizando-se então uma escolha entre as opções: i) pelo cálculo do preenchimento pela média ou; ii) pelo uso do modelo de CRNA para preenchimento.

Foram consideradas duas possibilidades para opção das médias: a média simples (MS) e a média ponderada pela distância (MP). Ao final, a metodologia analisou ainda os desempenhos dos modelos conjugados CRNA+MS e CRNA+MP, permitindo a escolha de qual modelo seria adotado para a realização do preenchimento das falhas em cada um dos postos (Modelo de CRNA sozinho ou modelo de CRNA+MS ou CRNA+MP).

Os modelos de CRNAs constituem um conjunto de recursos, programados em Matlab R2010a, para a seleção, de forma automática, de uma RNA, entre um conjunto existente de redes neurais, em função da disponibilidade de dados dos postos vizinhos, e sua utilização. O número de RNAs que podem ser disponibilizadas é o número de combinações possíveis de entradas disponíveis. Se o número de postos que podem constituir entradas para um modelo é “n”, a quantidade de RNAs que podem fazer parte do novo modelo é $2^n - 1$.

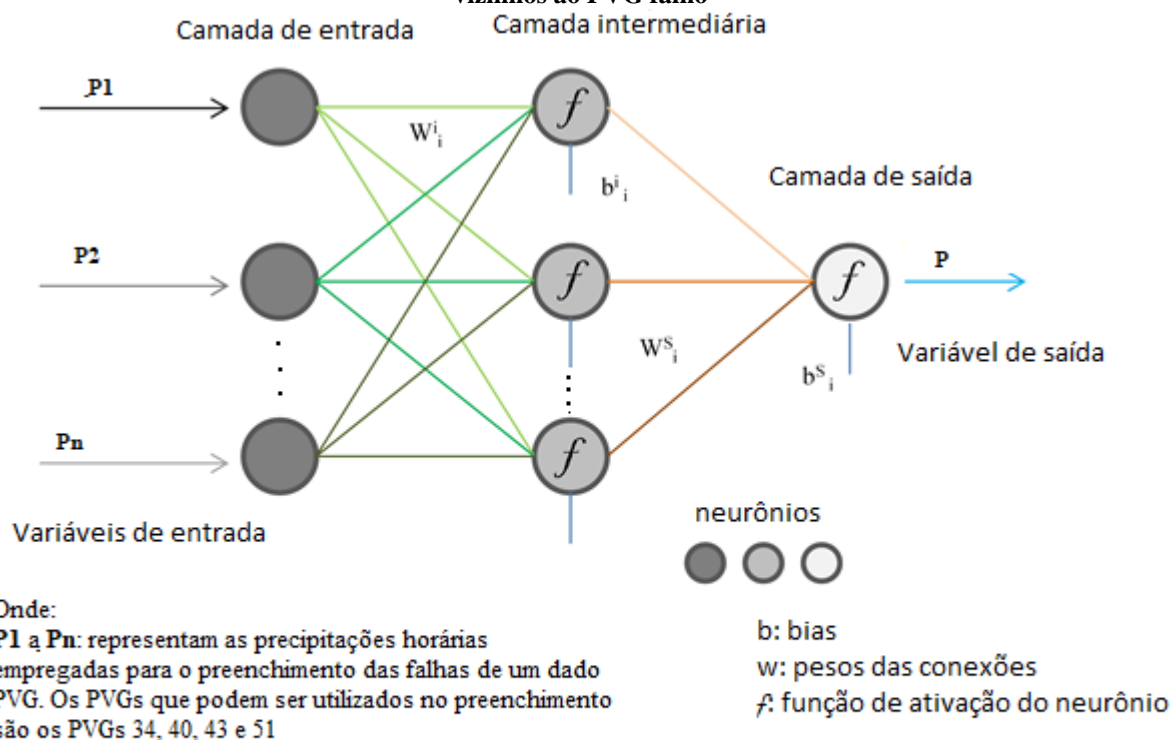
A ideia básica do método é a constituição de uma estrutura hiperdimensional de células, onde cada uma das $2^n - 1$ combinações constitui um endereço de memória, onde é armazenada uma rede neural, correspondente a esta combinação. Essa rede neural, com as informações das condições de treinamento (imprecisão, número de ciclos e repetições), das variáveis de entrada

¹⁰ Texto construído com base no artigo:

PEDROLLO, O.C.; AMARAL, S.; SARI, V.; CASTRO, N.M. dos R. Filling gaps in hourly and daily rainfall data using a model combining artificial neural networks. **Hidrological Science Journal**. Em reestruturação, a pedido dos revisores.

(com a quantidade, o nome de cada uma e os parâmetros de escalonamento), dos neurônios internos (com o número de neurônios e os pesos sinápticos de cada um), e das variáveis de saída (com a quantidade, o(s) nome(s), os pesos sinápticos dos neurônios e os parâmetros de escalonamento) correspondentes, é armazenada na forma de um *structure array* (segundo terminologia do Matlab R2010a), com campos especificados.

Figura 20 - Esquema representativo das RNAs desenvolvidas para preenchimento das falhas nos dados horários de precipitação na bacia do Taboão, utilizando dados de precipitação de outros pluviógrafos vizinhos ao PVG falho



O modelo utilizado conta com um conjunto de recursos para o armazenamento e a verificação das redes disponíveis, bem como para a busca de uma RNA específica em um modelo de combinações de redes neurais, em função das entradas disponíveis de um registro específico; que são informadas por meio de um código constituído por um vetor de dígitos binários, com um dígito para cada entrada do modelo, onde o “1” corresponde à disponibilidade do dado e o “2” à sua indisponibilidade.

Para cada pluviógrafo (PVG 34, 40, 43 e 51) foi então construído um modelo de RNA (modelo_34, modelo_40, modelo_43 e modelo_51) a partir de sete RNAs possíveis para as

entradas, sendo elas: [1 1 1]; [1 1 2]; [1 2 1]; [2 1 1]; [2 2 1]; [2 1 2]; [1 2 2], onde “1” indica a presença de dados de entrada no posto e o “2” a ausência de dados. Assim sendo, para cada modelo sempre haverá no mínimo um e no máximo três pluviógrafos de apoio para o preenchimento, totalizando, 28 RNAs para os quatro postos analisados.

No processo de treinamento de cada uma das RNAs, empregou-se metodologia semelhante à utilizada para determinação dos modelos de RNAs para estimativa da CSS (descrita no item 3.9, subitem 3.9.3). Inicialmente, efetuou-se a divisão da amostragem total disponível em dois conjuntos: um conjunto total de amostras de treinamento e um conjunto de amostras de verificação.

A etapa de validação foi aplicada ao total dos registros de treinamento, com uso de reamostragem, a qual consistiu, neste método, no uso de “n” partições do número total N de registros de treinamento, de forma que cada um dos “n” treinamentos foi realizado, alternadamente, com “n-1” das partições, e enquanto que a restante foi utilizada como amostra de validação. O total dos “n” treinamentos constituiu um experimento de teste de uma alternativa de complexidade, cujo resultado foi o conjunto de N saídas da rede neural, proporcionando um vetor de N erros para o cálculo da estatística decisiva do experimento.

O número de registros deslocados, alternadamente, da amostra de treinamento, para formar o conjunto de validação, dependeu do número de registros restantes, sendo, entretanto, suficiente para cada treinamento sucessivo. Recomenda-se, com base na experiência, mesmo em casos com menos dados, pelo menos 30 registros a cada procedimento com o algoritmo de treinamento, e que a composição de cada conjunto a ser sucessivamente utilizado para a validação seja definida por meio de um procedimento de amostragem sistemática, ou seja, por ordenamento dos registros segundo a variável de saída e posterior seleção com base em um fator de repetição igual ao número “n” de conjuntos. Portanto, a validação a que se faz referência resulta desse procedimento de reamostragem.

A primeira condição do método de pesquisa da complexidade foi atendida pela adoção de uma condição de finalização do treinamento, adequada para conter o superajustamento, e resultante de pesquisa preliminar. Esta pesquisa preliminar (etapa 1) consistiu na experimentação e avaliação do desempenho na validação, com uma RNA inicial (propositalmente superdimensionada), de cada valor decrescente da condição de finalização (máximo admitido, no treinamento, do erro absoluto médio). O valor desta condição a partir do qual o erro absoluto médio na validação começa a aumentar foi, então, adotado como critério

para a pesquisa da complexidade, uma vez que este foi considerado o limite para a interrupção do treinamento, para que não ocorresse superajustamento.

A pesquisa da complexidade (etapa 2), que consistiu na pesquisa do número de neurônios na camada interna foi, executada por tentativas (com a condição de finalização conhecida, resultante da pesquisa anterior), com a redução progressiva a partir da configuração utilizada na etapa 1, a cada experimento, do número de neurônios na camada interna, até que a capacidade de aproximação da RNA sofreu redução de desempenho (em relação ao modelo inicial, mais complexo), na validação. Admitindo-se que a condição de finalização pela aproximação determinada no treinamento seja adequada para evitar o superajustamento, e que o número máximo de ciclos admitidos seja suficiente para que, com graus de liberdade suficiente, ocorra o treinamento, a redução da capacidade de generalização, quando ocorrer, pode ser considerada como decorrente da insuficiência de complexidade da RNA.

Posteriormente, após as pesquisas realizadas, o treinamento final da RNA foi executado com o uso da condição de finalização (resultante da etapa 1), e com o número de neurônios para a camada interna obtido na etapa 2, usando-se toda a amostra de treinamento.

Tanto as pesquisas da condição de finalização e da complexidade, quanto o treinamento do modelo final, foram realizadas com repetições dentro de cada experimento de treinamento, para contornar os efeitos da inicialização aleatória, conferindo maior robustez ao método. Desta forma, nos procedimentos de pesquisa que requerem validação por reamostragem, adota-se a condição de finalização ou a complexidade do modelo cuja estatística de desempenho na validação correspondeu à mediana, entre as repetições dentro de cada experimento.

Do mesmo modo, no treinamento final do modelo adotou-se o treinamento cuja estatística de desempenho correspondeu à mediana, entre as estatísticas de desempenho das repetições, na aplicação com o total de registros de treinamento, porque os treinamentos mais bem-sucedidos ainda podem, em alguma medida, estar afetados por superajustamento.

O desempenho das estatísticas aplicadas foi analisado de acordo com as recomendações de Moriasi et al. (2007), para variáveis hidrológicas. Os dados ausentes nos quatro postos, isto é, sem possibilidade de preenchimento pelos modelos desenvolvidos, foram adotados como iguais aos registros monitorados na estação meteorológica instalada na bacia (PVG 13).

3.11.4 Temperatura máxima e mínima do ar, radiação solar, velocidade do vento, umidade relativa do ar e temperatura do ponto de orvalho

Os dados climáticos de entrada requeridos para simulação do modelo SWAT são séries históricas diárias de temperatura do ar máxima e mínima, radiação solar, umidade relativa do ar e velocidade do vento. Esses dados foram obtidos da estação climatológica localizada na cidade de Cruz Alta (código 02853005), nas coordenadas 28°36' S e 53°40' W (em UTM: 238553 m E e 6833021 m N, Fuso 22J), em uma altitude de 432 m e distante 18 km da área de Pejuçara. Essa estação é gerenciada pelo INMET.

Nesse estudo, foram considerados os dados diários (temperatura máxima e mínima do ar, radiação solar, velocidade do vento e umidade relativa do ar) do período compreendido entre 01/01/2008 até 31/12/2016 para a simulação do modelo SWAT. Os anos de 2008 e 2009 foram empregados apenas para aquecimento do modelo, não sendo considerados nas análises finais dos processos hidrossedimentológicos.

Além disso, foram também necessários os parâmetros de entrada: média mensal de temperatura máxima diária; média mensal de temperatura mínima; desvio padrão para a temperatura máxima diária de cada mês; desvio padrão para a temperatura mínima diária de cada mês; média diária de radiação solar para cada mês; média diária da temperatura do ponto de orvalho para cada mês e; média diária da velocidade do vento para cada mês.

Na Tabela 17 são apresentados os dados climáticos médios utilizados como entrada no banco de dados climáticos do modelo SWAT.

Tabela 17 - Dados climáticos médios mensais utilizados no modelo SWAT

Mês	DEWPT	SOLARAV	WNAV	TMPMX	TMPMN	TMPSTDMX	TMPSTDMN
Janeiro	19,181	19,032	1,674	29,848	18,742	0,891	0,805
Fevereiro	19,467	17,670	1,709	29,049	18,448	1,444	0,966
Março	18,368	15,431	1,711	28,110	17,229	1,394	1,071
Abril	15,737	11,538	1,693	25,555	14,663	1,355	0,995
Mai	12,814	8,796	1,577	21,371	11,547	1,387	1,326
Junho	11,586	6,368	1,712	19,478	10,002	1,378	1,619
Julho	10,284	7,722	1,768	18,570	9,030	1,869	1,769
Agosto	11,693	9,831	1,857	21,446	10,645	1,658	1,650
Setembro	12,628	11,369	2,044	21,952	11,654	1,875	1,282
Outubro	15,050	12,964	2,135	24,962	14,191	1,727	1,229
Novembro	15,577	17,881	2,155	27,613	15,881	1,742	1,235
Dezembro	17,815	18,943	1,905	29,410	18,238	1,837	1,176

Onde: TMPMX: média mensal de temperatura máxima diária (°C); TMPMN: média mensal de temperatura mínima diária (°C); TMPSTDMX: desvio padrão para a temperatura máxima diária de cada mês (°C); TMPSTDMN: desvio padrão para a temperatura mínima diária de cada mês (°C); SOLARAV: média diária de radiação solar para cada mês (MJ/m²/dia); DEWPT: média diária do ponto de orvalho para cada mês (°C); WNAV: média diária da velocidade do vento para cada mês (m/s)

Fonte: autora

Esses dados médios foram calculados utilizando a série histórica do período compreendido entre 01/09/1989 e 31/12/2016, conforme descrições e equações apresentadas em Neitsch et al. (2005, 2010, 2011).

3.11.5 Análise de sensibilidade, calibração e verificação do modelo SWAT

A análise de sensibilidade do modelo SWAT foi realizada com auxílio do *software* SWAT-CUP (algoritmo SUFI-2), buscando-se a definição dos parâmetros mais sensíveis para as condições estudadas (simulação dos processos hidrossedimentológicos), tendo sido realizada em conjunto com o processo de calibração do modelo.

A sensibilidade dos parâmetros no processo de análise de sensibilidade global baseou-se em valores para a estatística-t (*t-Stat*) e para o valor-p (*p-Value*). O *t-Stat* fornece uma medida da sensibilidade, onde as maiores barras indicam maior sensibilidade; enquanto que o *p-Value* determina a significância da sensibilidade, sendo que quanto mais próximo a zero maior é a significância.

A calibração dos processos hidrossedimentológicos seguiu a ordem proposta por Moriasi et al. (2007), tendo sido realizada automaticamente, com auxílio do *software* SWAT-CUP (algoritmo SUFI-2). Portanto, inicialmente realizou-se a calibração dos processos hidrológicos para, na sequência, realizar a calibração da produção de sedimentos.

Para a simulação dos processos hidrológicos, foram utilizados como parâmetros iniciais os valores previamente calibrados e verificados por Depiné (2014), apresentados na Tabela 13 (descrita anteriormente) e na Tabela 18 (disposta a seguir)

Já os parâmetros não calibrados pela autora, foram considerados como iguais ao sugerido no *default* do modelo SWAT. A autora utilizou a série de vazão de 11/01/2002 a 16/09/2004 para o processo de calibração do modelo SWAT, e o período de 01/01/2008 a 31/05/2011 para a verificação, considerando chuva horária como entrada do modelo e aplicação do método de infiltração de Green & Ampt.

Para a definição do parâmetro Alpha_Bf (constante de recessão do escoamento de base) o escoamento total monitorado no rio foi separado em dois componentes (escoamento de base e escoamento superficial) empregando-se uma técnica automática de filtro digital (ARNOLD et al., 1995; ARNOLD e ALLEN, 1999). O fluxo de base é importante para a correta definição do escoamento e do armazenamento de água no solo.

Tabela 18 - Parâmetros calibrados e verificados por Depiné (2014) na bacia do Taboão, considerando o período de calibração de 11/01/2002 a 16/09/2004 e de verificação de 01/01/2008 a 31/05/2011

Parâmetro	Definição	Valor inicial	Valor sugerido	Valor calibrado
Alpha_Bf	constante de recessão do escoamento de base	0,048	0,28 (Ferrigo, 2014) 1 (Baldissera, 2005) 0,2 (Lubitz, 2009)	1
Canmx	interceptação máxima da vegetação	0	0 - 9,65 (Lubitz, 2009)	40
Ch_N	valor de Manning para o canal principal	0,014	0,01 - 0,2 (Baltokoski, 2008)	0,06
Epc0	fator de compensação para uso de água pelas plantas	1	-	0,3
Esco	coeficiente de compensação da evaporação no solo	0,95	0,99 (Ferrigo, 2014) 0,28 - 0,82 - (Baltokoski, 2008)	0,7
Gw_Delay	tempo de recarga do aquífero	31	83 (Ferrigo, 2014) 0 - 47 (Baltokoski, 2008)	60
Gw_Revap	coeficiente que controla o fluxo de água da zona saturada para não saturada	0,02	0,1 (Ferrigo, 2014) 0,2 (Baldissera, 2005)	0,2
Gwqmn	profundidade do aquífero raso para escoamento de base	0	1068 (Ferrigo, 2014) 5000 (Baldissera, 2005)	2500
Rchrg_Dp	fração de percolação para o aquífero profundo	0,05	0,01 - 1 (Baltokoski, 2008)	0,9
Revapmn	profundidade de água no aquífero para que ocorra percolação	1	0 (Baldissera, 2005)	0,5
Surlag	atraso do escoamento superficial	4	1 (Lubitz, 2009)	9
Sls0il	comprimento da rampa lateral para o fluxo de sub-superfície	0	3 (Baldissera, 2005)	3
Lat_Ttime	tempo de retorno do fluxo lateral	0	31 (Baldissera, 2005)	31

Fonte: Depiné (2014)

Essa separação foi realizada com apoio do *software* SWAT Baseflow, um programa de filtro de fluxo de base que possibilita determinar a relação entre o escoamento superficial/de base e o fator alfa do escoamento de base (Alpha_Bf), requerido para calibração do modelo SWAT. O algoritmo desse programa foi desenvolvido com base em Arnold e Allen (1999) e o *software* é disponibilizado na base de dados do modelo SWAT no link <http://swat.tamu.edu/software/baseflow-filter-program/>.

Nessa pesquisa, a série total de dados de vazão disponível (2011 a 2016) foi dividida em uma parcela para a calibração e outra para a verificação do modelo SWAT, considerando-se aproximadamente 70% dos dados para a calibração e 30% para o processo de verificação do modelo. Os anos de 2013, 2014 e 2016 foram empregados para o processo de calibração e; os

anos de 2011 e 2015 foram utilizados para a verificação dos processos hidrológicos na bacia do Taboão. Essa divisão procurou assegurar uma representatividade dos dados, escolhendo-se períodos de dados com vazões elevadas para o processo de calibração e de verificação do modelo.

As séries de dados de precipitação e os dados climáticos utilizados abrangeram o período de 01/2008 a 12/2016. Dessa forma, o período de aquecimento do modelo SWAT (*warm-up*), para a estabilização das condições iniciais, foi considerado satisfeito pela simulação dos anos de 2008 e 2009. Os anos de 2010 e 2012 não foram considerados no estudo de modelagem, por caracterizarem-se como anos com característica mais atípica (mais secos) em relação aos demais períodos utilizados para a simulação (2011, 2013, 2014, 2015 e 2016). Além disso, o ano de 2010 apresentava muitas falhas nos dados de nível de água monitorados na bacia do Taboão e também, nos níveis de água das sub-bacias que poderiam ser utilizados para preenchimento das falhas existentes.

Para a calibração da produção de sedimentos, os parâmetros de entrada do modelo foram ajustados por meio de técnica automática, realizada com auxílio do *software* SWAT-CUP, com emprego do algoritmo SUFI-2. Após o processo de calibração estar completo, o modelo foi aplicado para a série de verificação, empregando-se os parâmetros determinados na calibração. A série utilizada para a calibração da produção de sedimentos, diária e mensal, compreendeu os anos de 2013 e 2015, e o processo de verificação foi realizado para o ano de 2014.

Na Tabela 19 descreve-se o resumo dos períodos utilizados para cálculo dos parâmetros médios do banco de dados do modelo SWAT e também, para as simulações realizadas com esse modelo; além do período empregado nos processos de calibração e de verificação da vazão e da produção de sedimentos com o *software* SWAT-CUP.

No cálculo da CSS, quando disponíveis dados de entrada de nível de água e turbidez, utilizou-se a RNA nível de água-turbidez x CSS. Entretanto, quando existiam falhas nos dados de turbidez optou-se por, inicialmente, preencher os dados de turbidez empregando o modelo RNA nível de água x turbidez para, na sequência, empregar os dados de turbidez no modelo RNA turbidez x CSS para determinação da CSS. Ou seja, após a determinação das falhas nos dados de turbidez, os valores de CSS foram estimados com base no modelo RNA que tem como entrada apenas os valores de turbidez.

A escolha por esse modelo de RNA, mesmo com desempenho um pouco menor em comparação a RNA que tem como entrada o nível de água e a turbidez simultaneamente, visou evitar o uso repetitivo do nível de água em dois modelos de RNAs sequenciais. Em outras

palavras, empregou-se o nível de água na RNA para previsão da turbidez, evitando-se empregá-lo novamente para a previsão da CSS (RNA nível de água-turbidez x CSS), utilizando-se, portanto, a RNA nível de água x turbidez para estimativa da turbidez, seguida da RNA turbidez x CSS para determinação da CSS.

Tabela 19 - Resumo dos períodos utilizados no modelo SWAT e no *software* SWAT-CUP, para cálculos dos parâmetros, realização das simulações e também, para a calibração e a verificação da vazão e da produção de sedimentos na bacia do Taboão

Período utilizado	Objetivo para o qual o período foi utilizado	Descrição dos parâmetros calculados com o período citado ou das variáveis utilizadas
01/09/1989 a 31/12/2016	Série histórica utilizada para a determinação dos parâmetros médios do banco de dados climáticos do modelo SWAT	PCPMM, PCPSTD, PCPD, PR_W1, PR_W2, PCPSKW, RAINHHMX, DEWPT, SOLARAV, WNDV; TMPMX, TMPMN, TMPSTDMX, TMPSTDMN
01/01/2008 a 31/12/2016	Período total simulado no SWAT. Esse período foi utilizado para as séries de entrada de precipitação e clima, para a simulação do modelo SWAT	1) <i>Dados climáticos com entrada diária:</i> radiação solar, velocidade do vento, umidade relativa do ar e; temperatura máxima e mínima do ar 2) <i>Dados de precipitação com entrada horária:</i> para os quatro pluviógrafos utilizados na pesquisa (PVGs 34, 40, 43 e 51)
01/01/2008 a 31/12/2009	Período de aquecimento do modelo SWAT	Período não utilizado para análise posterior das simulações. Utilizado somente para estabilização das condições iniciais o modelo SWAT
2013, 2014 e 2016	Período utilizado para a calibração da vazão no <i>software</i> SWAT-CUP	Dados de vazão média diária (calibração em escala diária) e média mensal (calibração em escala mensal)
2011 e 2015	Período utilizado para a verificação da vazão no <i>software</i> SWAT-CUP	Dados de vazão média diária (calibração em escala diária) e média mensal (calibração em escala mensal)
2013 e 2015	Período utilizado para a calibração da produção de sedimentos no <i>software</i> SWAT-CUP	Dados de produção de sedimentos total diária (calibração em escala diária) e total mensal (calibração em escala mensal)
2014	Período utilizado para a verificação da produção de sedimentos no <i>software</i> SWAT-CUP	Dados de produção de sedimentos total diária (calibração em escala diária) e total mensal (calibração em escala mensal)

Fonte: autora

Os parâmetros iniciais considerados para a realização da análise de sensibilidade dos processos hidrossedimentológicos, no *software* SWAT-CUP, foram aqueles sugeridos como de maior sensibilidade na Tabela 5 e na Tabela 6, em especial os parâmetros identificados como mais importantes em estudos realizados na região Sul do Brasil, além daqueles reportados por Arnold et al. (2012b).

Após a execução da análise de sensibilidade foram considerados para a etapa de calibração aqueles parâmetros identificados como de maior sensibilidade, para a simulação dos processos na bacia do Taboão.

Os índices de desempenho das simulações hidrológicas e da produção de sedimentos foram classificados conforme critérios estabelecidos por Moriasi et al. (2007).

4 RESULTADOS E DISCUSSÕES

Este tópico traz a discussão e a interpretação dos achados dessa pesquisa. Inicialmente são apresentados os resultados das estatísticas descritivas entre nível de água, turbidez e CSS (item 4.1). Na sequência são mostrados os resultados dos processos de preenchimento de falhas nos dados de precipitação horária (item 4.2), nas informações de nível de água (item 4.3) e; nos dados de turbidez (item 4.4) para a bacia do Taboão, necessários para simulação dos processos hidrossedimentológicos com o modelo SWAT. No item 4.5 são mostradas as equações explícitas ajustadas entre CSS, nível de água e turbidez, no item 4.6 são descritos os resultados para o modelo de RNA sem emprego da metodologia proposta e no item 4.7 são apresentados os modelos de RNAs utilizando a metodologia proposta (Método de Validação por Reamostragem) para treinamento da rede e estimativa da CSS.

Na sequência, são descritas as estatísticas gerais dos dados observados na bacia do Taboão (precipitação, temperatura máxima e mínima do ar, radiação solar, velocidade do vento, umidade relativa do ar, nível de água, vazão, turbidez e CSS); além dos resultados da produção de sedimentos diária, mensal e anual, estimados a partir da CSS e da vazão (item 4.8).

Por fim, são apresentados os resultados das etapas de calibração e de verificação da hidrologia e da produção de sedimentos utilizando o modelo SWAT e *software* SWAT-CUP, considerando entrada de precipitação horária, saídas diárias e emprego do método de infiltração de Green & Ampt (item 4.9).

4.1 Análise das estatísticas descritivas entre nível de água, turbidez e CSS¹¹

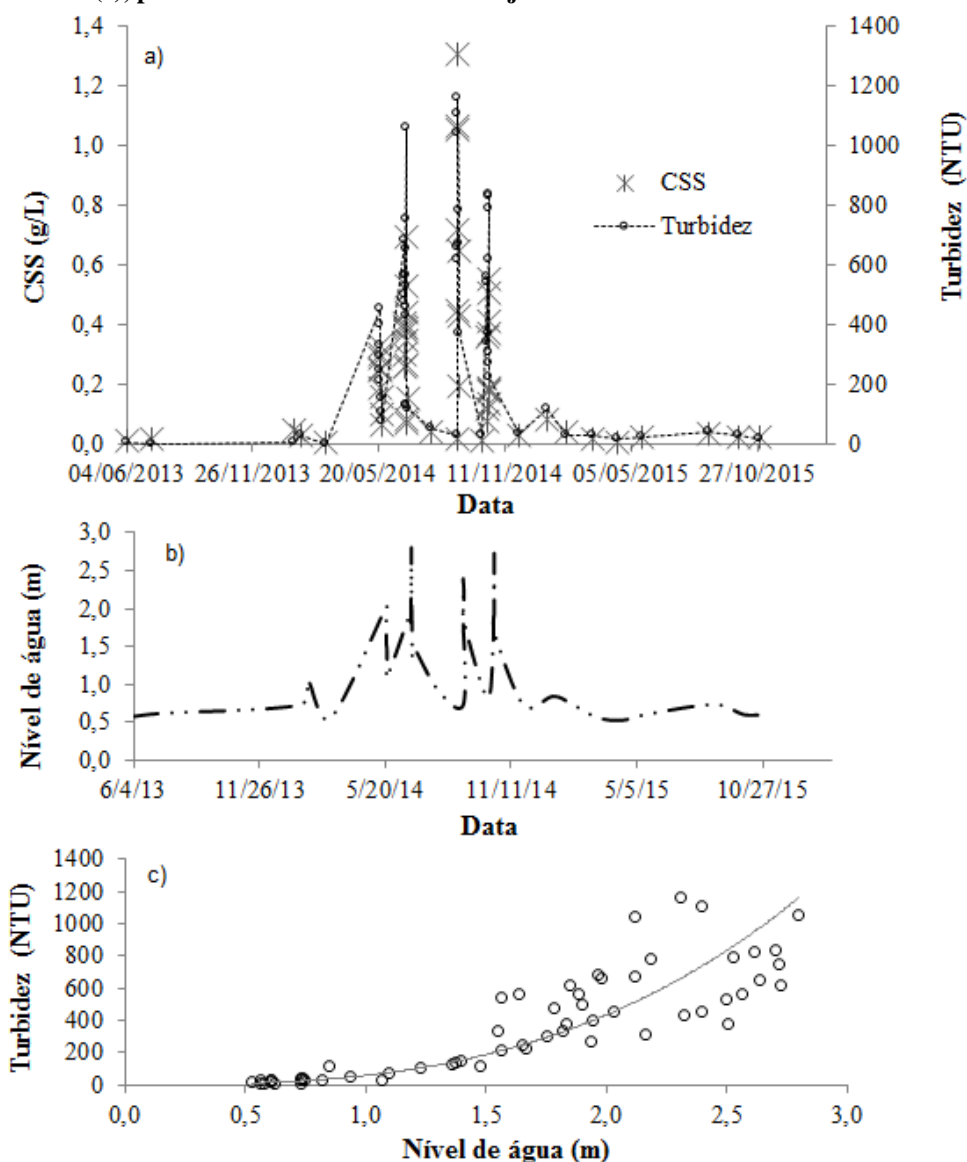
A Tabela 20 apresenta os resultados da CSS, da turbidez e do nível de água do rio para cada uma das 59 amostras coletadas entre junho de 2013 e outubro de 2015, bem como, as correspondentes estações climáticas em que cada monitoramento foi realizado.

Na Figura 21 são apresentadas as variações da turbidez e da CSS (Figura 21a), do nível de água (Figura 21b) e a relação nível de água-turbidez (Figura 21c), ao longo dos eventos e coletas periódicas, analisados no período amostrado. Os eventos monitorados abrangeram as quatro estações climáticas, sendo dois deles no inverno e um em cada uma das demais estações.

¹¹ Texto construído com base no artigo:

SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017. <https://doi.org/10.1007/s11269-017-1785-4>

Figura 21 - Variação da CSS e turbidez (a), variação do nível de água (b) e relação nível de água-turbidez (c), para os eventos analisados entre junho de 2013 e outubro de 2015



Fonte: Adaptado de Sari et al. (2017)

O nível de água variou entre 0,527 e 2,798 m, com média de $1,636 \pm 0,716$ m e mediana de 1,756 m. A turbidez observada oscilou entre um mínimo de 1,242 e um máximo de 1161,746 NTU, com média de $371,209 \pm 325,613$ NTU e mediana de 329,699 NTU.

Já a CSS mínima registrada foi igual a 0,008 g/L, com CSS máxima de 1,309 g/L, sendo a média igual a $0,272 \pm 0,280$ g/L e a mediana de 0,190 g/L. Os maiores valores de CSS estão relacionados aos eventos de cheia, mas nem sempre aos valores mais elevados de vazão.

Tabela 20 - Resultados das amostras coletadas entre junho de 2013 e outubro de 2015

Data	Estação climática	Nível de água (m)	Turbidez média (NTU)	CSS (g/L)
04/06/2013	Outono	0,578	3,745	0,010
10/07/2013	Inverno	0,617	1,242	0,016
22/01/2014	Verão	0,731	3,874	0,048
01/02/2014	Verão	1,065	28,819	0,031
06/03/2014	Verão	0,563	2,486	0,009
22/05/2014	Outono	2,030	452,546	0,327
22/05/2014	Outono	1,942	397,683	0,300
22/05/2014	Outono	1,822	329,699	0,245
22/05/2014	Outono	1,756	295,919	0,286
22/05/2014	Outono	1,648	245,701	0,190
22/05/2014	Outono	1,564	210,786	0,252
23/05/2014	Outono	1,396	151,097	0,160
23/05/2014	Outono	1,230	104,274	0,098
23/05/2014	Outono	1,096	74,372	0,065
25/06/2014	Inverno	1,964	681,225	0,404
25/06/2014	Inverno	1,902	499,575	0,299
25/06/2014	Inverno	1,885	564,258	0,395
25/06/2014	Inverno	1,782	474,088	0,257
26/06/2014	Inverno	2,798	1056,500	0,695
26/06/2014	Inverno	2,721	752,408	0,439
26/06/2014	Inverno	2,640	655,023	0,529
26/06/2014	Inverno	2,561	563,833	0,391
26/06/2014	Inverno	2,496	531,695	0,378
26/06/2014	Inverno	2,398	458,010	0,350
26/06/2014	Inverno	2,321	430,313	0,262
27/06/2014	Inverno	1,377	132,338	0,081
27/06/2014	Inverno	1,362	129,408	0,072
30/06/2014	Inverno	1,475	118,483	0,155
01/08/2014	Inverno	0,936	53,780	0,040
06/09/2014	Inverno	0,732	29,998	0,019
06/09/2014	Inverno	1,846	615,728	0,446
06/09/2014	Inverno	1,979	656,755	0,721
06/09/2014	Inverno	2,118	1041,843	1,066
06/09/2014	Inverno	2,312	1161,746	1,309
06/09/2014	Inverno	2,397	1107,682	1,051
07/09/2014	Inverno	2,186	782,846	0,645
07/09/2014	Inverno	2,118	668,325	0,432
07/09/2014	Inverno	1,832	373,114	0,193
10/10/2014	Primavera	0,821	31,750	0,011
18/10/2014	Primavera	1,638	557,438	0,078
18/10/2014	Primavera	1,561	544,228	0,116
18/10/2014	Primavera	1,551	338,663	0,360
19/10/2014	Primavera	2,528	787,405	0,413
19/10/2014	Primavera	2,618	829,613	0,509
19/10/2014	Primavera	2,701	835,615	0,553
19/10/2014	Primavera	2,729	616,353	0,372
19/10/2014	Primavera	2,505	373,588	0,136
19/10/2014	Primavera	2,165	308,318	0,175
19/10/2014	Primavera	1,938	272,255	0,190
20/10/2014	Primavera	1,664	224,318	0,185
29/11/2014	Primavera	0,730	34,406	0,031
09/01/2015	Verão	0,845	115,510	0,082
04/02/2015	Verão	0,742	31,040	0,043
11/03/2015	Verão	0,565	28,827	0,021
15/04/2015	Outono	0,527	17,902	0,008
19/05/2015	Outono	0,606	22,342	0,021
21/08/2015	Inverno	0,735	42,042	0,038
01/10/2015	Primavera	0,603	29,921	0,023
30/10/2015	Primavera	0,603	18,593	0,022

Fonte: Adaptado de Sari et al. (2017)

Estudos (GONZALEZ-HIDALGO et al., 2010; OEURNING et al., 2010; MEGNOUNIF et al., 2013; GIROLAMO et al., 2015) tem demonstrado que, de fato, os sedimentos suspensos são transportados em sua maioria durante eventos de cheia. Entretanto, essa relação não se dá de forma direta, na medida em que existe a atuação de uma complexidade de fatores sobre a bacia, os quais afetam a quantidade de sedimentos que passa por uma dada seção do rio, entre eles: a morfologia e as formações litológicas; a umidade antecedente do solo; a intensidade, o volume e a distribuição das precipitações; as variações sazonais da cobertura vegetal; as práticas agrícolas e o uso do solo; as distâncias das fontes de sedimentos em relação aos corpos hídricos, etc. (MEGNOUNIF et al., 2013).

Dessa forma, foram observadas, nessa pesquisa, situações em que vazões mais elevadas corresponderam a valores de CSS menores do que aqueles registrados para vazões um pouco inferiores (Figura 21a,b). A causa provável admitida é o fenômeno da histerese, que é o aparecimento de um atraso na evolução de um fenômeno físico em relação a outro, ou seja, os eventos de vazão e CSS não apresentam um sincronismo de fase (LEFRANÇOIS et al., 2007). Comumente, as CSS mais elevadas (superiores a 1 g/L) foram observadas durante os eventos monitorados no período do inverno (20 junho a 22 setembro). Em contrapartida, o escoamento na seção monitorada não apresentou grandes diferenças no transporte de sedimentos, ao longo da seção, para níveis do rio menores que 1 m, atingindo uma concentração máxima de 0,1 g/L.

Os dados de CSS monitorados mostraram-se bem correlacionados aos valores de turbidez medidos (Coeficiente de Pearson $R=0,913$; $p<0,05$), apresentando correlação menor em relação aos valores de nível de água ($R=0,708$; $p<0,05$). Os dados de turbidez também demonstraram boa correlação com as informações de nível de água ($R=0,853$; $p<0,05$), apresentando uma relação positiva e histerese do tipo horária.

Tais resultados são indicativos de uma boa possibilidade de ajuste de relações baseadas na turbidez e no nível de água para previsão da CSS; o que vai ao encontro de achados de outros estudos. A esse respeito, Walling (1977) enfatiza que os métodos que relacionam sedimento em suspensão e turbidez, e sedimento em suspensão e vazão (e, portanto, indiretamente pode-se fazer a mesma analogia ao nível de água), são os mais adequados para a estimativa dos sedimentos em suspensão.

4.2 Modelos de RNAs para preenchimento de falhas nos dados horários de precipitação (período: 2011 a 2016) a partir da precipitação em postos pluviométricos vizinhos¹²

Na Tabela 21 são mostradas as características gerais de cada posto pluviométrico utilizado nessa pesquisa. O posto com maior necessidade de preenchimento foi o PVG 51 com 52,06% dos dados ausentes, seguido do PVG 43 (19,48% dos valores), do PVG 34 e do PVG 40 com 11,05% e 10,42% dos dados ausentes, respectivamente.

Tabela 21 - Características dos postos pluviométricos e dos dados de chuva para o preenchimento dos PVGs 34, 40, 43 e 51, considerando o período de 01/01/2011 a 31/12/2016

PVG	Número de registros horários com dados disponíveis	% de falha nos dados	
34	46737	11,05	Total de registros horários no período (falhas + dados disponíveis) = 52545
40	47069	10,42	
43	42307	19,48	Total de registros com dados ausentes simultaneamente nos 4 postos = 1861
51	25207	52,06	

Fonte: autora

A correlação entre os postos utilizados para preenchimento das falhas pode ser observada na Tabela 22.

Tabela 22 - Correlações entre os postos pluviométricos com frequência horária

PVG	PVG 34	PVG 40	PVG 43	PVG 51
PVG 34	1	0,855	0,692	0,822
PVG 40	0,855	1	0,718	0,725
PVG 43	0,692	0,718	1	0,735
PVG 51	0,822	0,725	0,735	1

Fonte: autora

Na Tabela 23 são apresentadas as correlações entre os dados horários do PVG 13 e os demais PVGs (34, 40, 43 e 51), considerando: i) o período total de dados utilizados para determinação dos parâmetros médios do banco de dados climáticos do modelo SWAT (1989-2016); ii) apenas o período utilizado para definição dos modelos de RNAs desenvolvidos nessa pesquisa, para preenchimentos dos dados falhos de precipitação (2011 a 2016) e; iii) somente o período de dados a ser preenchido pelos modelos de RNAs desenvolvidos, em que houve

¹² Texto construído com base no artigo:

PEDROLLO, O.C., AMARAL, S.; SARI, V.; CASTRO, N.M. dos R. Filling gaps in hourly and daily rainfall data using a model combining artificial neural networks. **Hidrological Science Journal**. Em reestruturação, a pedido dos revisores.

efetivamente necessidade de utilização de algum preenchimento com dados do PVG 13 (06/2011 a 12/2016).

Tabela 23 - Correlações entre os postos PVG 34, 40, 43 e 51 e o PVG 13

Correlação 1989 a 2016 - período total dos dados utilizados para definição dos parâmetros médios do banco climático do modelo SWAT*				
	PVG 34	PVG 40	PVG 43	PVG 51
PVG 13	0,906	0,873	0,875	0,735
Correlação 2011 a 2016 - período analisado nessa pesquisa para calibração e verificação da vazão**				
	PVG 34	PVG 40	PVG 43	PVG 51
PVG 13	0,544	0,435	0,452	0,842
Correlação 06/2011 a 07/2016 - período em que, efetivamente, houve necessidade de realizar algum preenchimento de falhas na precipitação usando dados do PVG 13**				
	PVG 34	PVG 40	PVG 43	PVG 51
PVG 13	0,653	0,712	0,783	0,788

* Considerando nos cálculos os dados de precipitação do preenchimento efetuado por Depiné (2014)

** Sem considerar nos cálculos os dados de precipitação do preenchimento de falhas realizado nessa pesquisa

Fonte: autora

A chuva média é relativamente homogênea entre os quatro postos analisados, sendo que a precipitação média mensal, dos quatro postos, varia de 90,4 a 171,1 mm e a média de janeiro a dezembro é de 116,6 mm. A precipitação é bem distribuída no ano com ausência de um período específico de estiagem ou de cheia, confirmando os resultados obtidos por Depiné et al. (2014). A precipitação média anual para esse período é de 1490,6 mm.

Na Tabela 24 são descritos os números de ocorrência das intensidades de chuva maiores que 30, 20, 10, 5 e 0 mm/h, além da ausência de chuva (= 0 mm/h), na escala horária para cada posto no período analisado. A última coluna refere-se ao número total (N) de registros horários analisados para cada PVG.

Tabela 24 - Número de ocorrência e frequência (%) de chuva com intensidade maior que 30; 20; 10; 5; 0 mm/h e igual a zero

PVG	30 mm/h	20 mm/h	10 mm/h	5 mm/h	> 0 mm/h	= 0 mm/h	N
PVG 34	5 (0,0099%)	12 (0,0237%)	86 (0,17%)	339 (0,67%)	4064 (8,02%)	46619 (91,98%)	50683
PVG 40	4 (0,0085%)	48 (0,102%)	136 (0,29%)	414 (0,88%)	4552 (9,68%)	42491 (90,32%)	47043
PVG 43	5 (0,0118%)	22 (0,0521%)	108 (0,26%)	312 (0,74%)	3918 (9,27%)	38327 (90,72%)	42245
PVG 51	1 (0,004%)	7 (0,0278%)	41 (0,16%)	143 (0,57%)	1660 (6,59%)	23544 (93,41%)	25204

Fonte: autora

Observa-se que a maioria dos registros se refere a intensidades de chuva entre 0 e 5 mm/h, embora tenha acontecido alguns eventos com intensidades superiores a 30 mm/h, para os quatro postos. Eventos com intensidade superior a 10 mm/h, ocorreram entre 41 e 136 vezes e superiores a 5 mm/h ocorreram centenas de vezes no período analisado. Altas intensidades gerarão picos de vazão no exutório da bacia, que poderão não ser adequadamente simulados caso a simulação seja efetuada com dados diários de chuva.

Na Tabela 25 são apresentados os melhores resultados obtidos no preenchimento das precipitações horárias para as sete RNAs desenvolvidas para cada PVG, entre todas as proporções de treinamento simuladas (10, 15, 20, 25, 30, 35 e 40% dos registros disponíveis), conforme disponibilidade de dados em um ou mais pluviômetros vizinhos e o método de preenchimento a ser utilizado (RNA, MS ou MP). Também são mostrados o número de ocorrências das situações de disponibilidades das entradas de dados de precipitação de postos vizinhos e o número de neurônios resultantes no treinamento de cada modelo.

O método utilizado efetua a pesquisa para a busca ideal do número de neurônios, de forma automática. O número de neurônios selecionado pelo método variou de 2 a 6 para os dados horários. Já o número de registros utilizados para o treinamento, foi informado ao modelo, tendo sido testadas preliminarmente as diferentes proporções, e adotada a proporção de treinamento que resultou em melhor eficiência para cada modelo.

Percebe-se que a proporção ideal do número de registros variou para cada um dos modelos, sendo importante, portanto, realizar testes preliminares para a pesquisa do número de registros ideal a ser empregado no treinamento da rede. Para os modelos analisados, o número de registros utilizado para o treinamento variou de 667 a 20.274 (de um total de 52.545 registros disponíveis).

De forma geral, não foram observadas tendência entre número de neurônios e eficiência do modelo para as RNAs nos 28 modelos desenvolvidos. Também não se observou tendência entre o número de registros utilizados para o treinamento e a eficiência dos modelos, na medida em que a eficiência foi avaliada com base na série de verificação, que foi sempre a mesma, independentemente do número de registros selecionados da amostra total do treinamento, que foi efetivamente utilizado como representativo.

Tabela 25 - Estatísticas para os modelos de preenchimento dos dados horários de chuva para os PVGs 34, 40, 43 e 51, considerando emprego de RNAs, MS e MP

Modelo	Nº registros [222] sem entradas	Número de ocorrências	NS verificação RNA	NS Média Simples	NS Média Ponderada	Proporção de dados usados no treinamento	Nº de neurônios
Modelo_34_111	3348 (7,14%)	18827	0,84	0,74	0,81	30%-2000	6
Modelo_34_112		22063	0,64	0,48	0,57	20%-1333	3
Modelo_34_121		5659	0,80	0,80	0,83	30%-2000	3
Modelo_34_211		10	0,59	0,53	0,50	35%-2333	2
Modelo_34_221		711	0,59	0,53	0,53	40%-2666	2
Modelo_34_212		1407	0,39	-0,03	-0,03	20%-1333	3
Modelo_34_122		520	0,60	0,53	0,53	10%-667	2
Modelo_40_111		1867 (3,55%)	17300	0,85	0,79	0,85	35%-17737
Modelo_40_112	21781		0,69	0,69	0,72	20%-10136	2
Modelo_40_121	5655		0,77	0,76	0,80	25%-12670	5
Modelo_40_211	1537		0,60	0,67	0,66	35%-17737	3
Modelo_40_221	715		0,45	0,55	0,55	15%-7602	2
Modelo_40_212	1689		0,49	0,40	0,40	25%-12670	2
Modelo_40_122	2001		0,59	0,66	0,66	15%-7602	2
Modelo_43_111	2693 (5,12%)		22239	0,40	0,47	0,46	25%-12463
Modelo_43_112		21720	0,51	0,51	0,50	10%-4985	3
Modelo_43_121		716	0,44	0,43	0,44	25%-12463	2
Modelo_43_211		2247	0,41	0,51	0,49	20%-9970	2
Modelo_43_221		5	0,45	0,43	0,43	20%-9970	3
Modelo_43_212		863	0,44	0,43	0,43	25%-12463	3
Modelo_43_122		2062	0,35	0,30	0,30	35%-17448	2
Modelo_51_111		1861 (3,54%)	38501	0,86	0,61	0,58	40%-20274
Modelo_51_112	5458		0,64	0,56	0,57	40%-20274	5
Modelo_51_121	580		0,58	0,56	0,57	40%-20274	5
Modelo_51_211	2389		0,54	0,53	0,40	40%-20274	3
Modelo_51_221	837		0,56	0,56	0,56	40%-20274	2
Modelo_51_212	721		0,56	0,50	0,50	35%-17739	3
Modelo_51_122	2198		0,54	0,43	0,43	30%-15205	2

Descrição do nome dos modelos: para o “Modelo_34_112” => 34: indica o PVG para o qual a RNA foi desenvolvida (PVG 34); 112: o nº “1” indica disponibilidade de dados e o nº “2” indica ausência de dados, em cada um dos 3 PVGs que poderiam ser utilizados. Essa sequência de 3 números indica a ausência ou presença de dados nos demais PVGs, considerados em ordem crescente (34, 40, 43, 51). Assim, para o exemplo considerado, o primeiro nº “1” indica que existem dados no PVG 40, o segundo nº “1” indica que há dados no PVG 43 e o nº 2 (3º nº na sequência 112) indica que não existem dados no PVG51. Portanto, essa RNA será utilizada quando estão disponíveis dados dos PVGs 40 e 43 para preenchimento das falhas no PVG 34.

Fonte: autora

O desempenho das RNAs variou entre um NS de 0,35 (Modelo_43_122)— considerado “Insatisfatório” pelos critérios propostos por Moriasi et al. (2007)— e um NS de 0,84 (Modelo_34_111), avaliado como “Muito Bom” pelos mesmos autores. Em 16 das 28 RNAs desenvolvidas, o desempenho dos modelos de RNAs foi superior às médias simples (MS) ou às médias ponderadas (MP); o que representa 57,14% dos casos avaliados. O PVG 34 apresentou seis dos sete modelos de RNAs superiores em relação ao preenchimento realizados pelas médias, já o PVG 40 mostrou menor aproveitamento das RNAs, com somente dois modelos de RNAs resultando em melhor desempenho do que as médias.

Na Tabela 26 são descritos os desempenhos médios gerais para cada modelo de combinações de RNAs (CRNA), Média Simples (MS), Média Ponderada (MP), CRNA+MS e CRNA+MP.

Tabela 26 - Desempenho geral dos modelos de CRNAs, MS e MP utilizados para preenchimento dos dados horários dos PVGs 34, 40, 43 e 51

Modelos	NS na etapa de verificação				
	CRNA	MS	MP	CRNA + MS	CRNA + MP
Modelo_34	0,786	0,657	0,685	0,786	0,783
Modelo_40	0,754	0,707	0,741	0,771	0,774
Modelo_43	0,417	0,565	0,577	0,424	0,577
Modelo_51	0,729	0,633	0,614	0,729	0,729

Fonte: autora

Os modelos de CRNA demonstraram melhores desempenhos quando comparados aos modelos da MS e MP, com exceção do Modelo_43. Para os PVGs 34 e 51, o desempenho conjunto dos modelos de CRNA com as médias (CRNA+MS e CRNA+MP) foi equivalente ao das CRNAs. Isso ocorreu porque, nesses casos, quase todas as RNAs foram melhores do que as MSs e MPs correspondentes, com exceção dos Modelo_34_121 e Modelo_51_221 (com, respectivamente, 5659 e 837 dos 52545 registros). Portanto, a utilização das médias correspondentes, nesses casos, não foi suficiente para produzir efeito significativo no coeficiente de eficiência, o que não compensou a utilização do modelo combinado CRNAs + MP para o preenchimento de falhas horárias dos postos 34 e 51.

O PVG 40, por sua vez, apresentou um comportamento diferente, pois o modelo de CRNA foi melhor do que os modelos respectivos de MS e MP, embora apenas duas redes neurais tenham sido melhores do que as médias respectivas (ou seja: as correspondentes ao Modelo_40_111 e ao Modelo_40_212 com, respectivamente, 17.300 e 1.689 registros, do total de 52.545). Isso ocorreu porque o Modelo_40_112, que é utilizado por 21781 registros, por exemplo, apresenta desempenho semelhante entre as redes neurais e as respectivas médias, e

porque as diferenças a favor dos modelos de médias não são suficientes para resultar em vantagem para esses modelos. O mais interessante, porém, é que os modelos conjugados, CRNA+MS e CRNA+MP conseguiram extrair o melhor do conjunto das abordagens, CRNA e médias (MS e MP), resultando nos melhores desempenhos.

No PVG 43, o desempenho da MP foi equivalente ao modelo de CRNA+MP, pois em todos os casos de possíveis combinações de entradas, as MPs foram melhores do que o modelo de CRNA+MP, sendo assim, o modelo de CRNAs não foi recomendado para o preenchimento nessas situações. Isso aconteceu porque, para o modelo_43, as RNAs que foram melhores do que as médias simples foram as [1 2 1], [2 1 2] e [2 2 1], cujas quantidades reais de ocorrência de falhas na aplicação foram, respectivamente, 716, 863 e 5, de um total de 52545 registros falhos. Então, o modelo de CRNAs+MS não poderia ter resultado significativamente melhor do que o modelo MS, já que o número de registros para os quais esse modelo teve a oportunidade de ser aplicado foi proporcionalmente pequeno.

Da mesma forma, as RNAs melhores que as MP foram as [2 2 1], [2 1 2] e [1 2 2], cujo número de ocorrências, na série real, foram de 5, 863 e 2.062, do total de 52.545 registros. Assim sendo, o desempenho do modelo de CRNA+MP foi praticamente igual ao modelo mais simples, que emprega apenas as MPs, não havendo vantagem prática na aplicação do modelo combinado.

Os resultados encontrados nessa pesquisa podem ser considerados muito bons, considerando-se que foram efetuados preenchimentos de dados horários de precipitação. Em comparação aos desempenhos observados nesse estudo, resultados reportados por outros autores, que também utilizaram RNAs para o preenchimento de dados de chuva, mostraram desempenhos semelhantes ou, até mesmo, inferiores aos verificados nessa pesquisa, utilizando escalas de tempo maiores para o preenchimento das falhas (dados diários, mensais, etc.), em que a variabilidade dos dados é, geralmente, menor.

Lucio et al. (2007), por exemplo, empregaram RNAs para estimar falhas em séries de dados mensais de precipitação (1961-2005), para o estado do Rio Grande do Sul. Os autores reportaram bons desempenhos para o preenchimento com RNAs, com erros inferiores a 5% e R^2 variando entre 0,51 e 0,72, embora os modelos tenham demonstrado tendência à superestimativa dos valores de precipitação calculados.

Já Nkuna e Odiyo (2011) desenvolveram modelos baseados em RNAs (de base radial) para o preenchimento de lacunas nos dados diários de precipitação, na bacia do rio Luvuvhu (África do Sul), utilizando como entrada dados de chuva de estações vizinhas. Na calibração

das RNAs, o NS variou de 0,55 e 0,85 e na etapa da verificação, o NS oscilou entre 0,49 e 0,75. A pesquisa produziu dados de precipitação confiáveis, possibilitando seu uso para futuras modelagens hidrológicas na bacia.

Almeida e Almeida (2012), por sua vez, analisaram o desempenho de RNAs para o preenchimento de falhas em séries de precipitação diária, em duas localidades com regimes de precipitação distintos: em uma região tropical, no Ceará, e em uma região subtropical, no Paraná. O coeficiente de Pearson (R) variou de 0,81 a 0,88 para as estações no Paraná e de 0,29 a 0,49 nas estações do Ceará; com desempenho das RNAs no Paraná muito superior ao Ceará.

Em pesquisa realizada por Kashani e Dinpashoh (2012), no Irã, foram avaliadas 11 técnicas de inteligência artificial para estimativa de dados climatológicos, em três condições climáticas diferentes. Os modelos foram desenvolvidos para preenchimento de informações falhas nos dados mensais de: temperatura mínima e máxima do ar; temperatura média do ar; umidade relativa; velocidade do vento e precipitação, entre os anos de 2001 e 2005. Os resultados mostraram que, frequentemente, os modelos de RNAs apresentam melhor eficiência para o preenchimento de lacunas nos dados de precipitação, se comparados a outros métodos. O coeficiente de desempenho foi igual a 0,33 para a condição climática “seca”, 0,95 para a condição climática “semiúmida, úmida e extra-úmida” e; 0,97 para a condição climática “semi-seca e seca”. Nessa pesquisa, os resultados de desempenho observados para o preenchimento com modelo de RNAs também foram, em sua maioria, superiores aos verificados para os demais métodos testados (média simples e ponderada).

Estudo realizado por Mwale, Adeloye e Rustum (2012), empregando RNAs não supervisionadas (mapa auto-organizado), mostrou desempenho variável para o preenchimento das lacunas de dados diários de chuva, entre 1978 e 2008, na bacia do rio Shire (Malawi), conforme as entradas utilizadas. No total, as combinações de informações de chuva, fluxo e nível de água em diferentes estações resultaram em 28 variáveis de entrada possíveis. Os resultados reportados mostraram um R^2 variando entre 0,42 e 0,58 quando dados de nível de água, de fluxo e de chuva são empregados como entrada dos modelos. Em contrapartida, quando os dados de chuva são simulados sozinhos, o R^2 variou entre 0,46 e 0,71; aumentando para uma variação entre 0,70 e 0,93 quando as estações disponíveis são agrupadas em *clusters* (3 no total) para a simulação.

Dounia et al. (2014) efetuaram o preenchimento de falhas de dados mensais de chuva, na região Nordeste da Argélia, por meio de RNAs, utilizando uma estação pluviométrica com

dados mensais, para o período de 1965 a 1995. O desempenho das RNAs para o preenchimento dos dados de precipitação mensal apresentou resultados muito bons (NS=0,95).

Depiné et al. (2014) utilizaram RNAs não automatizadas para preenchimento de dados horários de precipitação, na mesma bacia desse estudo, para o período de 1989 a maio de 2011. Os autores obtiveram resultados muito bons (NS de verificação superiores a 0,9) quando o preenchimento foi realizado para intervalos curtos de tempo (de 12 a 30 dias de cada vez), tendo sido, portanto, necessária a execução de centenas de modelos para realizar o preenchimento de uma série de 10 anos de dados.

4.3 Modelos de RNAs para preenchimento de falhas dos dados de nível de água a partir de informações de chuva média e do nível de água nas bacias do Donato, Turcato, Alemão e Andorinhas¹³

Na Tabela 27 são apresentados os melhores resultados de desempenho dos modelos de RNAs na etapa de verificação, obtidos para uma série de dados que utiliza em torno de 500 registros para o treinamento e 3 repetições iniciais, com número máximo de ciclos de 300.000 ou 500.000.

Já na Tabela 28 são descritas as características dos períodos falhos e cada um dos modelos empregados para o preenchimento das falhas no nível de água na bacia do Taboão, destacando-se: os períodos de início e de fim das falhas nos dados de nível de água na bacia do Taboão; os postos fluviométricos em que os dados de nível de água estão falhos; a quantidade de dias falhos no ano; o número de registros falhos em cada ano para o intervalo de preenchimento dos dados (10 min) e; o percentual de falhas anuais.

O ano de 2010 (não utilizado para a modelagem no SWAT) apresentou a maior porcentagem de falhas, com necessidade de preenchimento (33,7% dos dados), seguido dos anos de 2016 (14,4%) e 2015 (9,1%). Os anos de 2013 e 2014 não apresentaram falhas nas informações de nível de água monitoradas na bacia do Taboão, enquanto que o ano de 2011 apresentou um número muito pequeno de falhas nos registros. Assim sendo, nesses três anos, não foi necessário realizar o preenchimento dos níveis de água nessa bacia por meio de RNAs.

¹³ Texto construído com base no artigo:

PEDROLLO, O.C.; CASTRO, N.M dos R.; SARI, V.; AMARAL, S. Estimate of water level and turbidity data from monitored data of precipitation and water level, using artificial neural networks. Artigo em elaboração para submissão.

Tabela 27 - Melhores resultados de desempenho dos modelos de RNAs desenvolvidos para o preenchimento dos dados de nível de água na bacia do Taboão

Estatísticas dos melhores modelos RNAs desenvolvidos																						
Ano	Modelo	Reg	Ciclos (mil)	Rep	Treinamento						validação						Verificação					
					NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE
2010	Don_Tur_Ch_valcruz_2010	504	500	3	0,960	4,03	19,35	34,80	6,31	9,04	0,954	1,16	7,24	31,72	1,91	3,23	0,959	1,32	5,25	34,49	1,87	2,78
	Don_Ch_valcruz_2010janjul	502	500		0,964	2,49	12,56	23,19	3,92	5,91	0,929	2,53	7,75	22,41	3,19	4,38	0,830	3,45	1,40	36,59	4,61	6,67
	Ch_valcruz_2010janjul	501	300		0,520	14,52	51,22	61,96	17,15	21,78	0,018	12,00	26,07	61,84	14,28	16,32	0,452	8,17	21,99	60,95	993,00	11,98
2011	Don_Tur_Ch_valcruz_2011	503	300	3	0,931	18,39	43,84	88,84	20,25	24,08	0,827	8,54	24,14	44,11	9,37	12,31	0,869	7,30	17,53	88,24	7,89	9,94
2013	Don_Tur_Ch_valcruz_2013	505	300	3	0,907	3,95	23,72	33,02	6,53	9,53	0,910	1,98	6,41	19,46	2,51	3,26	0,740	2,84	10,73	30,66	3,80	5,15
2014	Don_Tur_Ch_valcruz_2014	504	300	3	0,957	6,18	26,90	37,39	8,55	11,82	0,883	5,52	10,91	25,16	5,75	6,68	0,679	6,20	21,26	42,01	7,46	9,83
2015	Don_Ch_Ale_valcruz_2015	506	300	3	0,954	9,29	32,21	41,86	12,29	15,87	0,944	3,16	7,74	39,08	3,97	5,90	0,658	4,20	30,54	92,79	8,10	13,54
	Don_Ch_And_Ale_valcruz_2015	508			0,979	6,67	22,37	34,30	8,45	10,76	0,919	2,78	16,92	51,15	4,44	7,57	0,689	9,51	21,12	103,83	10,24	13,92
	Don_Ch_valcruz_2015	504			0,943	14,00	42,84	63,41	16,50	21,02	0,824	8,22	20,96	61,04	9,84	13,16	0,702	5,23	38,48	83,74	10,13	16,44
2016	Don_Ch_And_Ale_valcruz_2016	507	300	3	0,950	13,01	48,05	91,64	15,84	21,39	0,946	4,25	10,39	33,90	4,68	5,74	0,917	3,42	13,06	92,34	4,46	6,29
	Don_Ch_And_valcruz_2016	507			0,901	5,38	11,61	37,36	5,64	7,26	0,785	3,78	15,27	56,29	5,46	8,18	0,770	4,11	16,06	71,28	5,62	8,45
	Don_Ch_And_Ale_valcruz_2016majjul	505			0,981	0,52	3,80	16,04	0,98	1,78	0,983	0,65	3,45	6,83	1,00	1,48	0,966	0,66	3,33	16,04	1,16	2,13
	Don_Ch_And_valcruz_2016majjul	503			0,998	0,28	1,28	1,88	0,41	0,57	0,998	0,30	0,99	1,93	0,39	0,51	0,960	0,81	5,57	7,92	1,47	2,23

Legenda:

Rep: n° de repetições iniciais Ciclos: n° máximo de ciclos executados Reg: n° de registros na série de treinamento período sem falha nos dados monitorados na bacia do Taboão

Descrição do nome do modelo: para o modelo "Don_Tur_Ch_valcruz_2010" => Don_Tur_Ch: indica que foram utilizadas na RNA as entradas de nível de água nas bacias do Donato e do Turcato, além da chuva média; "valcruz": indica que foi utilizada a metodologia que divide a série total de dados em 3 partes (treinamento, validação e verificação), aplicando-se o método da validação cruzada para evitar o superajustamento da rede; "2010": indica o ano para o qual a RNA foi desenvolvida

Fonte: autora

Tabela 28 - Características dos períodos falhos e modelos empregados para o preenchimento dos dados de nível de água na bacia do Taboão, para o período de 2010 a 2016

Ano a ser preenchido: 2010							
Falhas início	Falhas fim	Posto fluviométrico com dado falho	Modelo usado para o preenchimento	Dias falhos	MIN	Registros falhos (10 min)	% Falha anual
01/01/10 00:00	14/01/10 08:35	Tab, Turc	Don_chu_valcruz_2010janjul	13,4	19235,0	1923,5	33,7
14/01/10 08:45	30/01/10 16:05	Tab, Turc e Don	Chu_valcruz_2010janjul	16,3	23480,0	2348,0	
30/01/10 16:15	04/05/10 00:15	Tab, Turc	Don_chu_valcruz_2010janjul	93,3	134400,0	13440,0	
Total =				123,0	177115,0	17711,5	
Ano a ser preenchido: 2011							
zero falhas => não é necessário preencher							
Ano a ser preenchido: 2012							
Falhas início	Falhas fim	Posto fluviométrico com dado falho	Modelo usado para o preenchimento	Dias falhos	MIN	Registros falhos (10 min)	% falha anual
13/01/12 13:55	14/01/12 13:25	Tab	não choveu, preenchido conforme variação do nível no rio	1,0	1410,0	141,0	2,0
26/07/12 05:15	01/08/12 17:15	Tab	não choveu, preenchido conforme variação do nível no rio	6,5	9360,0	936,0	
Total =				7,5	10770,0	1077,0	
Ano a ser preenchido: 2013							
zero falhas => não é necessário preencher							
Ano a ser preenchido: 2014							
Falhas início	Falhas fim	Posto fluviométrico com dado falho	Modelo usado para o preenchimento	Dias falhos	MIN	Registros falhos (10 min)	% Falha anual
24/10/14 16:25	24/10/14 16:35	Tab	falha única => não é necessário preencher por modelos	0,0	10,0	1,0	0,0
Ano a ser preenchido: 2015							
Falhas início	Falhas fim	Posto fluviométrico com dado falho	Modelo usado para o preenchimento	Dias falhos	MIN	Registros falhos (10 min)	% Falha anual
08/01/15 20:25	08/01/15 23:55	Tab	preenchido regressão linear (melhor que modelo)	0,1	210,0	21,0	9,1
30/10/15 14:05	01/11/15 07:25	Tab	Don_chu_valcruz_2015	1,7	2480,0	248,0	
01/11/15 07:35	26/11/15 23:55	Tab, Turc	Don_Chua_And_Ale_valcruz_2015 (realizada transição linear entre os dois períodos)	25,7	36980,0	3698,0	
27/11/15 00:05	28/11/15 00:05	Tab, Turc e Ale	Don_chu_valcruz_2015	1,0	1440,0	144,0	
01/12/15 00:15	05/12/15 14:35	Tab	Don_Chua_And_Ale_valcruz_2015	4,6	6620,0	662,0	
Total =				33,1	47730,0	4773,0	
Ano a ser preenchido: 2016							
Falhas início	Falhas fim	Posto fluviométrico com dado falho	Modelo usado para o preenchimento	Dias falhos	MIN	Registros falhos (10 min)	% Falha anual
31/05/16 23:55	28/06/16 18:45	Tab e Ale	Don_Chua_And_valcruz_2016maijul	27,8	40010,0	4001,0	14,4
28/06/16 18:55	23/07/16 15:55	Tab	Don_Chua_And_valcruz_2016maijul	24,9	35820,0	3582,0	
07/10/16 14:25	07/10/16 15:05	Tab	preenchido com regressão linear a partir do nível anterior e posterior (poucos registros falhos)	0,0	40,0	4,0	
Total =				52,7	75870,0	7587,0	

Fonte: autora

Para o ano de 2012, não foi possível desenvolver modelos de RNAs com bom desempenho para realizar o preenchimento das falhas de nível de água na bacia do Taboão. Essa não adequação pode ter sido uma consequência direta da influência do fenômeno La Niña, ocorrido entre o final de 2011 e 2012; caracterizando esse ano de 2012 como atípico (mais seco) em toda a região. De fato, em muitas das lavouras da bacia do Taboão, o plantio agrícola não foi realizado ou teve seu desenvolvimento prejudicado nesse ano de 2012, em decorrência da estiagem prolongada. Em razão disso e, por haver problemas no armazenamento dos registros para a maioria dos pluviômetros nesse ano de 2012, os dados desse período não foram considerados nas análises posteriores realizadas com o modelo SWAT.

Das 13 RNAs desenvolvidas para o preenchimento das falhas nos níveis de água no Taboão para os anos de 2010 a 2016, apenas uma delas (modelo “Chu_valcruz_2010janjul”) foi classificada como de desempenho “Satisfatório” ($0,50 < NS \leq 0,65$) durante o treinamento e; as demais se enquadraram como de “Muito Bom” desempenho ($0,75 < NS \leq 1,00$), conforme critérios estabelecidos por Moriasi et al. (2007). A RNA com pior desempenho está relacionada ao ano com maior número de falhas nos registros, o que pode ter contribuído para as piores estatísticas observadas.

Nas etapas de validação e de verificação, a RNA “Chu_valcruz_2010janjul” foi considerada com desempenho “Insatisfatório” ($NS \leq 0,5$) enquanto que, 12 RNAs foram enquadradas como de “Muito Bom” desempenho na validação e; para o processo de verificação, sete redes foram consideradas com desempenho “Muito Bom” e cinco com “Bom” desempenho ($0,65 < NS \leq 0,75$).

Tais resultados indicam que os modelos de RNAs configuram-se em uma boa alternativa para o preenchimento de dados falhos nos registros de nível de água na bacia do Taboão, quando informações de chuva e de nível de água nas bacias adjacentes estão disponíveis.

O modelo com melhor desempenho foi o “Don_Ch_And_Ale_valcruz_2016maijul”, com NS de 0,981 e 0,966 para as etapas de treinamento e de verificação, respectivamente. Esse modelo emprega a chuva média com filtro exponencial, além de informações de nível de água em três bacias, duas anteriores à bacia do Taboão (bacias do Donato e Alemão) e; em uma bacia posterior (bacia do Andorinhas). A RNA desenvolvida mostrou boas estatísticas dos índices de erro analisados ($Ea(50)$; $Ea(95)$; $Ea(Max)$, EaM e $RMSE$) e também, uma boa representatividade da série de verificação, não utilizada para treinamento da rede; indicando boa capacidade de predição dos dados falhos nesse ano.

Por outro lado, o pior desempenho foi observado para o modelo “Chu_valcruz_2010janjul”, com NS igual a 0,520 no treinamento e 0,452 na verificação da rede. Esse modelo empregou somente informações de chuva para o preenchimento dos níveis de água no Taboão, tendo sido utilizado para preenchimento de 2.348 registros falhos (ou 16,3 dias), para a situação mais crítica; quando todos os dados de nível de água nas bacias auxiliares estavam ausentes. As estatísticas de desempenho dos erros analisados (Ea(50); Ea(95); Ea(Max), EaM e RMSE) também demonstraram os piores resultados entre os modelos testados, com erros mais elevados em relação aos demais modelos.

Os modelos de RNAs efetivamente utilizados para o preenchimento das falhas no nível de água na bacia do Taboão, para o período utilizado nesse estudo (2011 a 2016) foram: os modelos “Don_Chuv_valcruz_2010janjul” e “Chu_valcruz_2010janjul” no ano de 2010; a RNA “Don_Chuv_valcruz_2015” em 2015 e; para o ano 2016, o modelo “Don_Chuv_And_valcruz_2016maijul”.

Nas Figuras 22 a 26 são apresentados, para os modelos utilizados no preenchimento das falhas de nível de água no Taboão: os valores de nível de água observado e simulado em relação à reta de ajuste ideal (Figura 22a a Figura 26a); o erro verificado entre os valores calculados e observados de nível de água (Figura 22b a Figura 26b); e o comportamento dos valores de nível de água calculados e observados (Figura 22c a Figura 26c, Figura 22d a Figura 26d), considerando os processos de treinamento e de verificação dos modelos, para cada um dos anos em que foram empregadas RNAs no preenchimento das falhas.

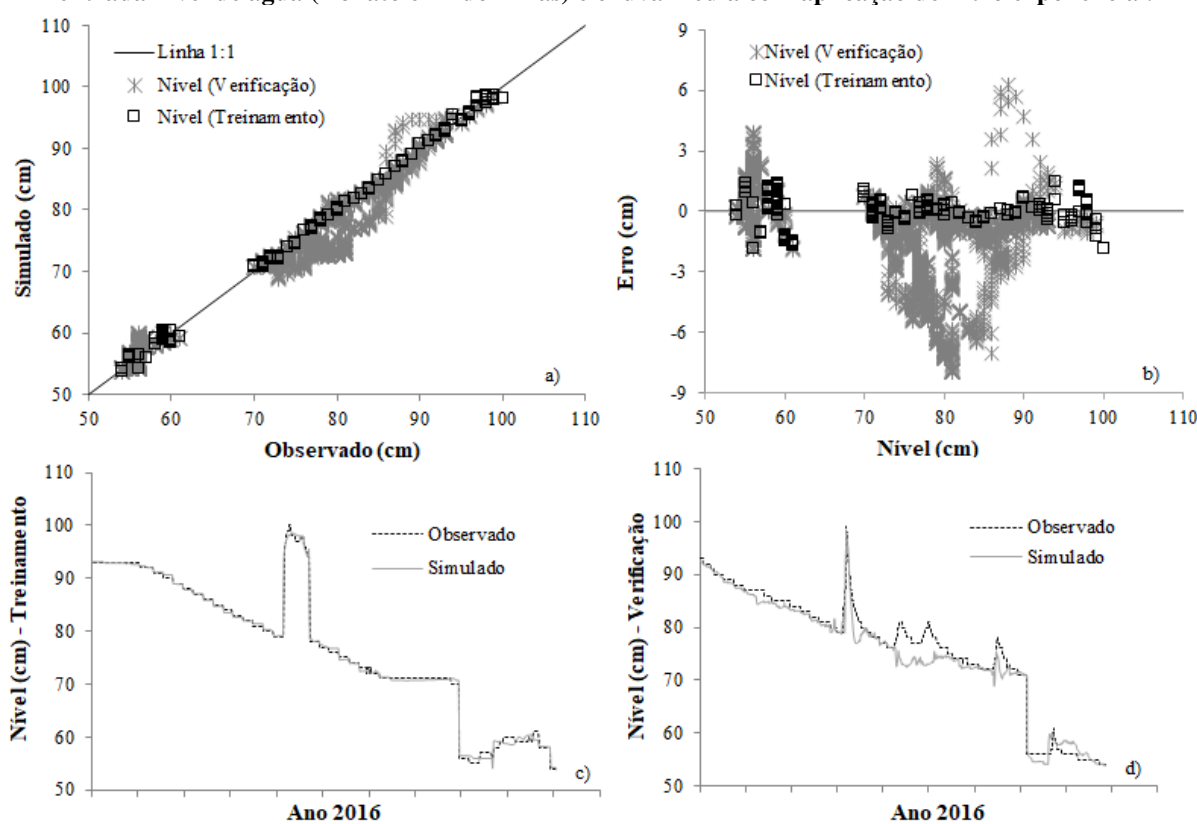
Uma análise desses resultados permite observar que, de modo geral, os modelos mostraram-se capazes de representar a variação geral do comportamento do nível de água ao longo dos eventos, em cada um dos anos analisados (Figura 22c a Figura 26c, Figura 22d a Figura 26d), com uma boa relação entre os dados observados e simulados (Figura 22a a Figura 26a).

Contudo, as RNAs demonstraram uma tendência à subestimativa dos valores simulados para os anos de 2016, 2015 (modelo que utiliza dados de nível e de chuva) e 2010 (modelo que emprega apenas dados de chuva), nos processos de verificação. Por outro lado, existiu uma tendência à superestimativa dos valores calculados para a rede que usa dados de chuva média (com filtro temporal exponencial) e informações de nível de água na bacia do Donato, tanto para o ano de 2015 quanto para o de 2010.

As melhores relações entre os dados observados e simulados são verificadas para os anos de 2016 e 2015 (Figura 22a, Figura 23a e Figura 24a), com maiores divergências em

relação à reta de ajuste ideal observada para o ano de 2010 (Figura 25a e Figura 26a), em que o desempenho do modelo foi considerado insatisfatório no processo de verificação da rede treinada. Considerando-se os processos de treinamento e de verificação das RNAs utilizadas para o preenchimento das falhas, verificou-se que os menores erros ocorreram para o ano de 2016, com valores variando entre 1,5 e 8,0 cm (Figura 22b).

Figura 22 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chru_And_valcruz_2016maijul, respectivamente, para o ano de 2016 e as variáveis de entrada nível de água (Donato e Andorinhas) e chuva média com aplicação de filtro exponencial.



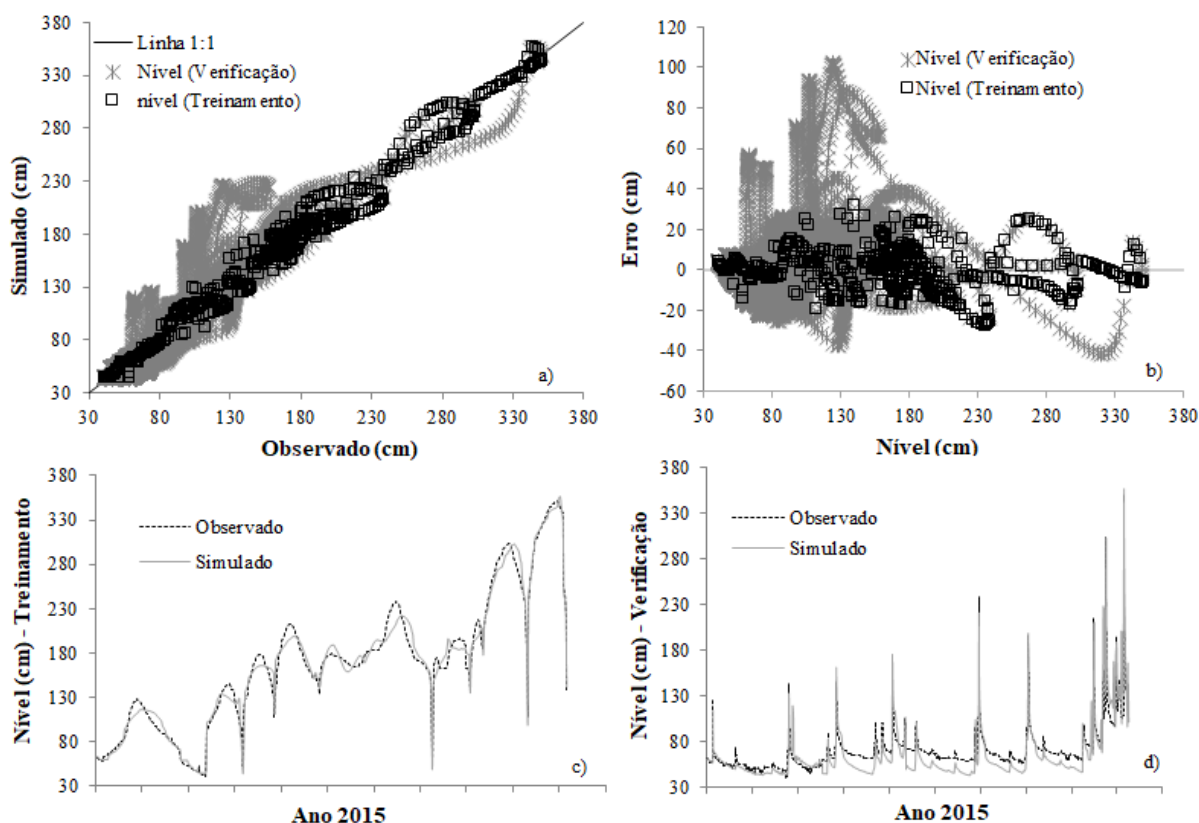
Fonte: autora

Na sequência, são observados erros de menores proporções para o ano de 2010, para o modelo que usa dados de chuva e nível de água (Figura 25b), com valores variando entre 14 e 37 cm. Já para a rede que utiliza somente dados de chuva para preencher as falhas de nível de água no Taboão, no ano de 2010, os erros verificados variaram entre 25 e 62 cm (Figura 26b).

No ano de 2015, os erros oscilaram entre 26 e 62 cm (Figura 23b) para a RNA que empregou como entrada o nível de água em três bacias (Donato, Alemão e Andorinhas), além de informações de chuva média com aplicação de filtro exponencial. Por outro lado, quando

empregado somente o nível de água na bacia do Donato, somadas às informações de chuva média, com filtro exponencial, os erros variaram entre 46 e 64 cm (Figura 24b).

Figura 23 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo *Don_Chru_And_Ale_valcruz_2015*, respectivamente, para o ano de 2015 e as variáveis de entrada nível de água (Donato, Alemão e Andorinhas) e chuva média com aplicação de filtro exponencial.



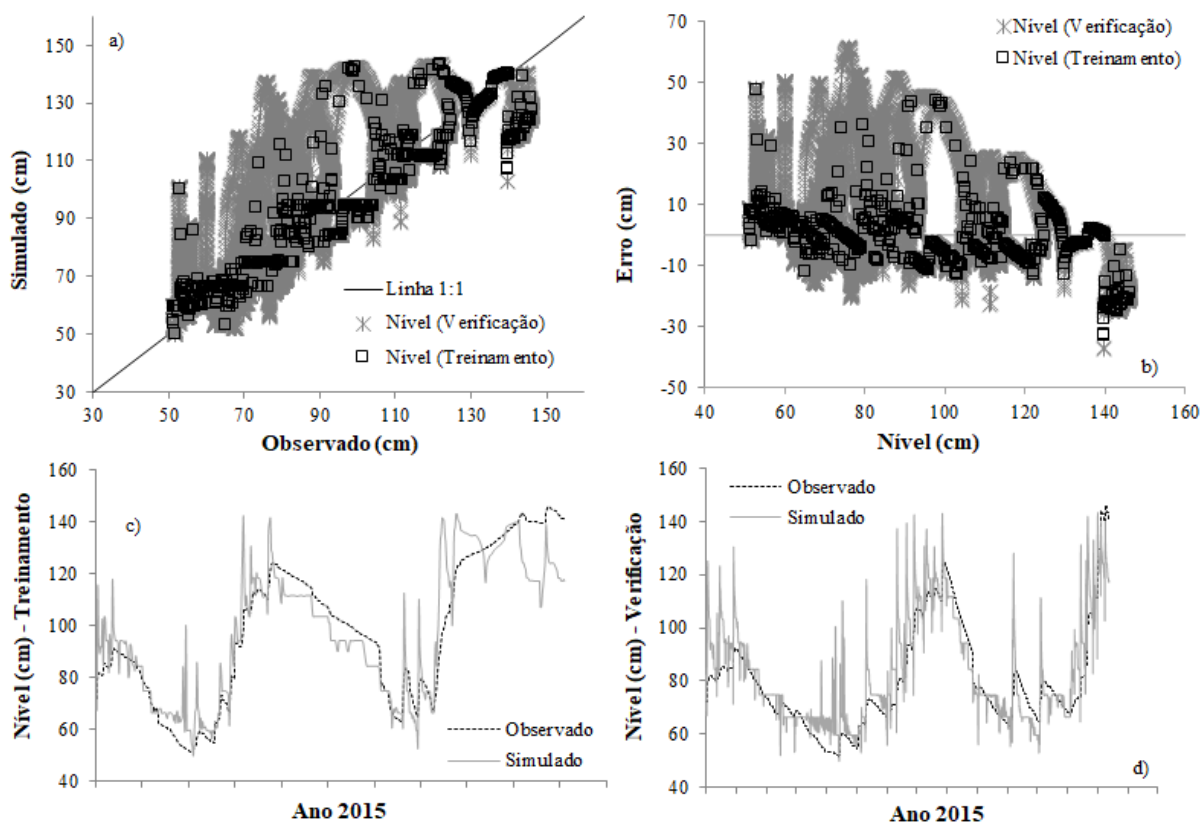
Fonte: autora

Dentre as RNAs efetivamente usadas para preenchimento das falhas (citadas anteriormente), o modelo “*Don_Chru_valcruz_2010janjul*” ($NSv=0,830$) foi a rede que mais vezes foi solicitada para a execução do preenchimento. Esse modelo utilizou dados de nível de água na bacia do Donato e ainda, registros de chuva média com filtro exponencial; tendo sido classificado como de desempenho “Muito Bom” em todas as etapas de desenvolvimento da RNA (treinamento, validação e verificação). Tal RNA foi empregada para o preenchimento de 13.440 registros de 10 min falhos no ano de 2010.

O segundo modelo mais acionado foi o “*Don_Chru_And_valcruz_2016maijul*”, usado para completar as lacunas de 4.001 registros ausentes no ano de 2016. Esse modelo também apresentou desempenho “Muito Bom” em todas as etapas; utilizando para o preenchimento do

nível de água, informações de nível de água em duas bacias, uma anterior ao Taboão (Donato) e outra posterior (Andorinhas), além de dados de chuva média com filtro exponencial.

Figura 24 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chu_valcruz_2015, respectivamente, para o ano de 2015 e as variáveis de entrada nível de água (Donato) e chuva média com aplicação de filtro exponencial.



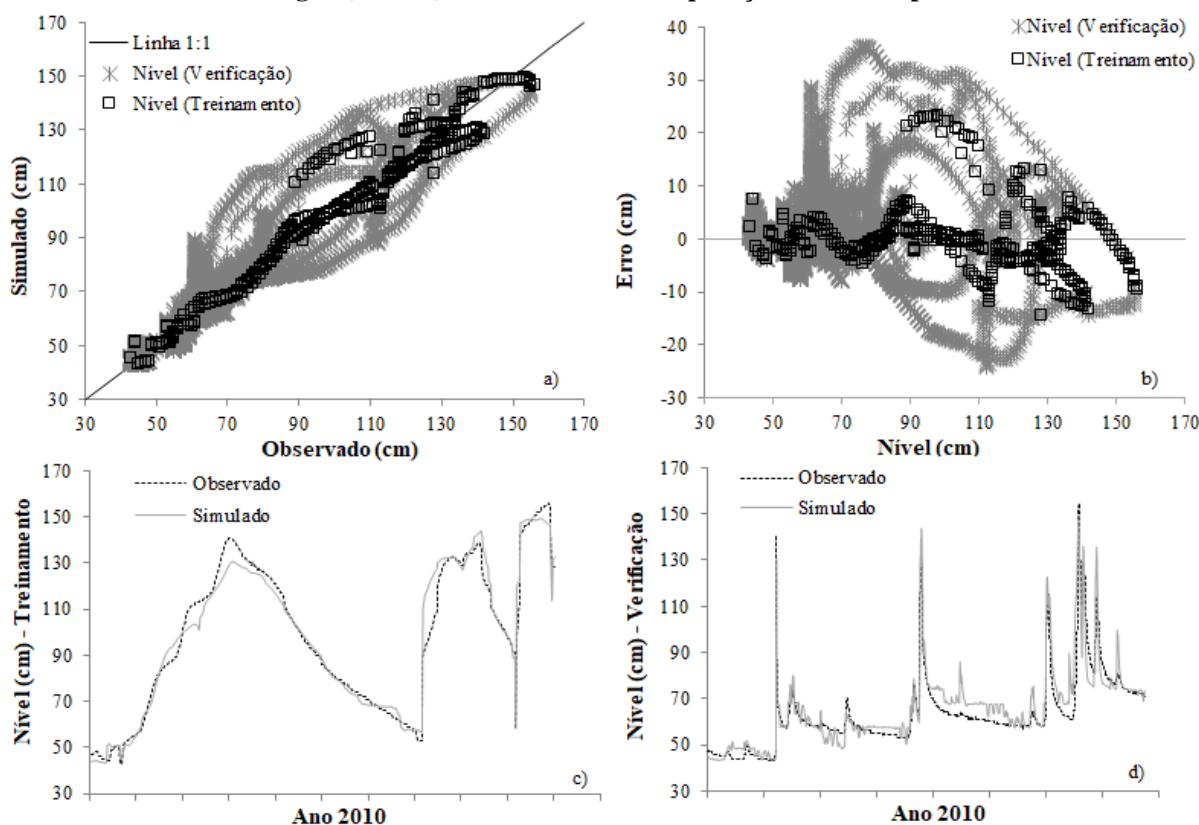
Fonte: autora

O terceiro modelo mais empregado foi o “Don_Chu_And_Ale_valcruz_2015”, usado para preenchimento de 3.698 registros de 10 min. Essa RNA utilizou dados de nível de água em três bacias (Donato, Alemão e Andorinhas), além das informações de chuva média com aplicação de filtro exponencial. A classificação dessa rede foi de desempenho “Muito Bom” no treinamento e na validação e, de “Bom” desempenho na etapa de verificação.

Para o preenchimento das falhas no ano de 2010, o segundo modelo mais acionado foi aquele que apresentou desempenho “Insatisfatório” nas etapas de validação e de verificação da RNA. Em razão disso, na simulação posterior dos processos hidrológicos, com uso do modelo SWAT, testou-se a alternativa de calibração com e sem esse ano de 2010, a fim de se verificar a influência, sobre a calibração, desse preenchimento de menor qualidade das falhas nos dados de nível de água na bacia do Taboão. Por fim, optou-se pela exclusão desse ano em tal etapa,

seja pela grande necessidade de preenchimento requerida, seja por 2010 se tratar de um ano mais atípico (mais seco) em relação aos demais anos presentes no período simulado no modelo SWAT (2011, 2013, 2014, 2015 e 2016).

Figura 25 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Don_Chru_valcruz_2010janjul, respectivamente, para o ano de 2010 e as variáveis de entrada nível de água (Donato) e chuva média com aplicação de filtro exponencial.



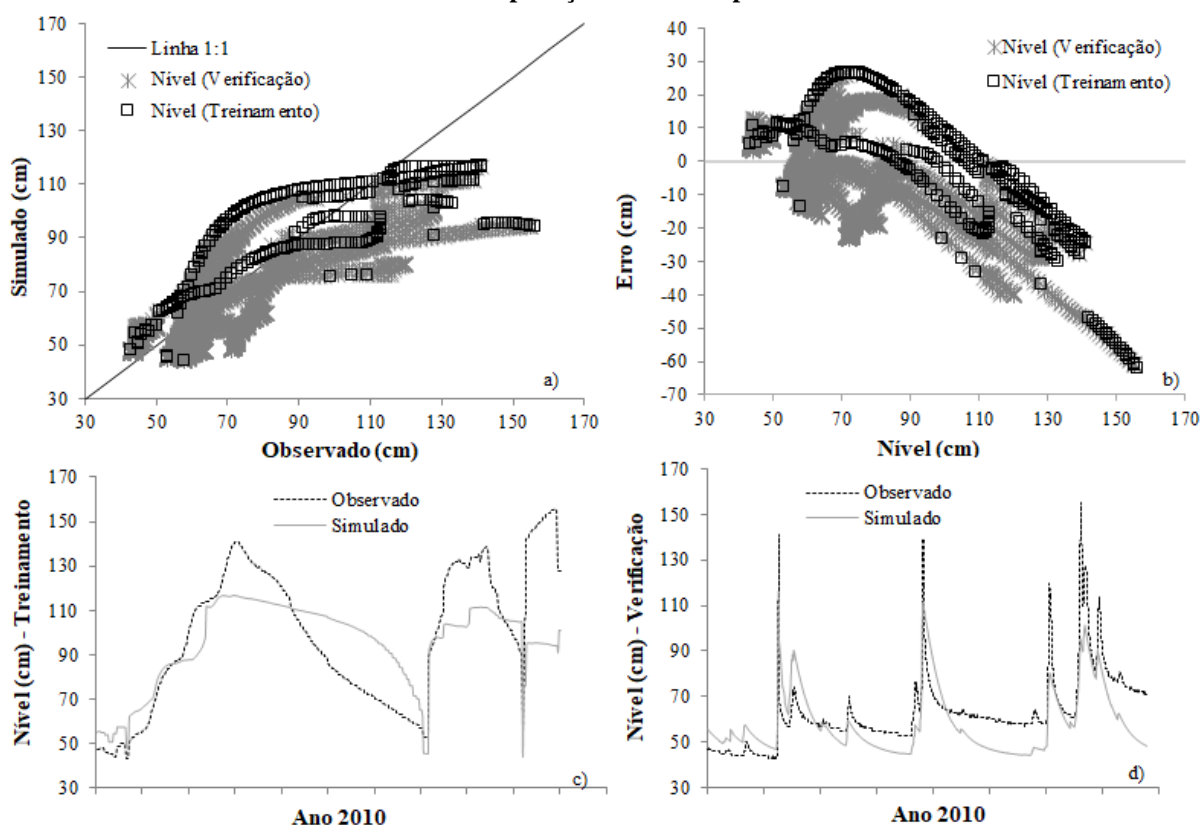
Fonte: autora

De fato, a grande quantidade de falhas nos dados de nível de água para esse ano de 2010, na bacia do Taboão e também nas sub-bacias utilizadas nos modelos de preenchimento, gerou a necessidade de utilização da RNA que emprega somente entrada de precipitação para preenchimentos das falhas. Todavia, como esse ano de 2010 pode ser caracterizado como um ano mais seco, em que comumente as precipitações são mais variáveis, temporal e espacialmente e; além disso, por ser a umidade do solo menor, a reposição do preenchimento utilizando apenas informações de precipitação apresenta maiores limitações e, justamente por isso, optou-se por descartar esse ano de 2010 das análises posteriores com o modelo SWAT.

De maneira geral, pode-se interpretar que os modelos de RNAs desenvolvidos para o preenchimento das falhas de nível de água na bacia do Taboão representam uma alternativa

interessante para a obtenção de séries contínuas de vazão, possibilitando o uso posterior dos dados para a modelagem hidrossedimentológica. Os resultados de desempenho foram apontados, usualmente, como bons a muito bons, mesmo sendo utilizada nessa pesquisa uma escala de tempo menor (10 min) do que a reportada por outros autores, que trabalharam em um passo de tempo diário ou mensal e; mesmo sendo mais rápida a resposta das bacias analisadas nesse estudo, o que torna a modelagem e o preenchimento das falhas mais difícil, em razão da variabilidade dos dados.

Figura 26 - Nível de água observado e simulado na bacia do Taboão em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de nível de água (b), e comportamento dos valores de nível de água calculados e observados (c, d); considerando os processos de treinamento e de verificação do modelo Chu_valcruz_2010janjul, respectivamente, para o ano de 2010 e a variável de entrada chuva média com aplicação de filtro exponencial.



Fonte: autora

Dastorani et al. (2010), por exemplo, testaram o desempenho de técnicas Neuro-Fuzzy (ANFIS- *Adaptive Network based Fuzzy Inference Systems*) e RNAs, em comparação às tradicionais técnicas comumente empregadas para o preenchimento de falhas no fluxo de água. Foram analisadas informações de fluxo mensal monitoradas em quatro estações, localizadas no Irã. As RNAs mostraram ótima eficiência na previsão das lacunas mensais para as diferentes estações de monitoramento, com R^2 variando entre 0,914 e 0,958.

Mwale, Adeloye e Rustum (2012) utilizaram RNAs não supervisionadas (mapa auto-organizado), com 28 variáveis de entrada possíveis (combinações de chuva, fluxo e nível de água em diferentes estações), para o preenchimento das lacunas de dados diários de chuva e; de fluxo e nível de água na bacia do rio Shire (Malawi), no período de 1978 a 2008. Os resultados descritos pelos autores mostraram que a abordagem utilizada produziu estimativas confiáveis para o preenchimento das falhas; muito embora, o desempenho dos modelos tenha sido influenciado em função da interferência conjunta (correlação) das variáveis empregadas como entrada dos modelos. O R^2 para o preenchimento dos níveis de água e do fluxo variou entre 0,48 e 0,88, quando utilizadas como entrada informações conjuntas de nível de água, chuva e fluxo. Por outro lado, quando os modelos para previsão do fluxo e do nível foram treinados em separado das entradas de chuvas, o desempenho melhorou, com variação do R^2 entre 0,81 e 0,97. Os autores atribuíram essa melhoria ao fato de que os dados de nível/fluxo estarem mais bem correlacionados entre si, em comparação às informações de chuva que eram monitoradas em diferentes pluviômetros, e considerando que a chuva comumente apresenta maior variabilidade espaço-temporal.

Já Shiau e Hsu (2016) utilizaram RNAs, do tipo *feedforward* e de base radial, para preencherem as falhas dos dados de fluxo diário na bacia do rio Gaoping (sul de Taiwan). Foram consideradas como entradas das redes as informações de fluxo, com diferentes atrasos de tempo, além de informações de chuva em estações próximas. Os autores também testaram divisões da amostra para treinamento por estações do ano. O coeficiente de eficiência das redes *feedforward* variou entre 0,183 e 0,710 para a etapa de verificação da rede (1991-1992); enquanto que, para as redes de base radial, a eficiência dos modelos variou entre 0,215 e 0,974, conforme as variáveis de entrada testadas, considerando o mesmo período de verificação.

4.4 Modelos de RNAs para preenchimento de falhas nos dados de turbidez a partir de informações de nível de água na bacia do Taboão¹⁴

Os modelos de RNAs para preenchimento das falhas de turbidez, empregando dados de nível de água no exutório da bacia do Taboão, foram desenvolvidos para a realização de correções e/ou de preenchimento das falhas nos registros de turbidez, monitorados entre 2013

¹⁴ Texto construído com base no artigo:

PEDROLLO, O.C.; CASTRO, N.M dos R.; SARI, V.; AMARAL, S. Estimate of water level and turbidity data from monitored data of precipitation and water level, using artificial neural networks. Artigo em elaboração para submissão.

e 2015. A amostra total disponível foi dividida em partes, cada uma delas abrangendo um período de tempo dos dados totais (2013 a 2015), tendo sido treinada uma RNA para cada uma das partes consideradas.

Na Tabela 29 são descritos os desempenhos dos modelos de RNAs na etapa de verificação, considerando as diferentes divisões testadas para a série de dados (total de partes em que a amostra original foi subdividida) e, as diferentes quantidades de registros empregados no processo de treinamento dos modelos desenvolvidos para cada parte dessa divisão. A divisão da série total em 20 partes resultou em desempenho muito insatisfatório para algumas das parcelas testadas e, em razão disso, essa divisão não foi apresentada nos resultados descritos na referida tabela.

De acordo com o critério de classificação de desempenho proposto por Moriasi et al. (2007) para a estatística NS, a maioria dos modelos testados pode ser classificada como de desempenho “Bom”, seguido da classificação “Satisfatório” e “Muito Bom”, respectivamente.

No entanto, em todos os testes realizados, pelo menos uma das partes da parcela de dados subdivididos foi considerada como de desempenho apenas “Satisfatório”; estando essa parcela comumente associada a valores de turbidez elevados. Quando se aumentou acima de seis partes a subdivisão da amostra total, as redes começaram a apresentar resultados de desempenho “Insatisfatório” para alguns dos modelos de RNAs testados (algumas das partes da divisão da amostra total de dados).

Entre os testes realizados para as diferentes subdivisões da amostra total de dados disponível, a divisão da série total em 5 partes (ou seja: quando desenvolvidas 5 RNAs para o período de dados de 2013 a 2015) foi considerada a mais satisfatória. Portanto, os modelos desenvolvidos para essa divisão foram, posteriormente, utilizados para o preenchimento das falhas nos dados de turbidez. Como para cada uma das cinco partes foi desenvolvida uma RNA específica, testando-se em cada uma delas, a utilização de diferentes quantidades de dados para a série de treinamento, escolheu-se como modelo final, em cada situação (cada parte), as RNAs com melhor desempenho.

Na Tabela 30 estão descritas as estatísticas de desempenho de cada uma das RNAs desenvolvidas para as cinco partes da série total de dados; considerando as etapas de treinamento, de validação e de verificação das redes.

Seguindo os critérios definidos por Moriasi et al. (2007) para a estatística NS, no processo de treinamento das RNAs, o desempenho das redes foi classificado como “Bom” para quatro das cinco divisões da amostra total e; como “Muito Bom” para a parte 1. Tanto na etapa

de validação quanto na de verificação, duas das cinco partes da amostra total resultaram em RNAs com desempenho “Muito Bom”, uma delas foi classificada com desempenho “Bom” e; dois dos modelos foram considerados “Satisfatórios”.

Tabela 29 - Desempenho dos modelos de RNAs na etapa de verificação, para diferentes divisões da série de dados (total de partes), considerando diferentes quantidades de registros (Reg) no processo de treinamento

Divisão da série total	Parte	NS verificação				
		Reg: 500	Reg: 800	Reg: 1000	Reg: 1500	Reg: 2000
4	1	0,702	0,693	0,699	0,707	0,694
	2	0,741	0,736	0,746	0,745	0,742
	3	0,630	0,666	0,669	0,666	0,676
	4	0,596	0,575	0,585	0,587	0,594
5	1	0,720	0,703	0,723	0,715	0,708
	2	0,747	0,741	0,752	0,757	0,737
	3	0,565	0,596	0,579	0,595	0,573
	4	0,776	0,786	0,801	0,785	0,804
	5	0,585	0,604	0,603	0,610	0,589
6	1	0,731	0,757	0,754	0,775	0,767
	2	0,701	0,698	0,705	0,708	0,709
	3	0,743	0,718	0,733	0,740	0,750
	4	0,570	0,587	0,571	0,588	0,594
	5	0,735	0,727	0,739	0,732	0,738
	6	0,502	0,548	0,550	0,540	0,529
8	1	0,747	0,758	0,760	0,765	0,770
	2	0,514	0,514	0,523	0,550	0,532
	3	0,743	0,740	0,761	0,760	0,750
	4	0,705	0,737	0,766	0,772	0,040
	5	0,610	0,611	0,634	0,637	0,020
	6	0,762	0,763	0,763	0,774	0,060
	7	0,559	0,558	0,549	0,570	0,050
	8	0,701	0,729	0,726	0,723	0,700
10	1	0,748	0,788	0,800	0,790	0,789
	2	0,614	0,632	0,617	0,626	0,609
	3	0,406	0,379	0,420	0,418	0,405
	4	0,762	0,766	0,752	0,757	0,747
	5	0,774	0,778	0,777	0,780	0,766
	6	0,628	0,629	0,620	0,638	0,625
	7	0,679	0,703	0,675	0,687	0,675
	8	0,870	0,868	0,870	0,867	0,865
	9	0,491	0,516	0,502	0,482	0,478
	10	0,693	0,719	0,720	0,710	0,697

Fonte: autora

Tabela 30 - Estatísticas de desempenho dos modelos de RNAs para a divisão em 5 partes da amostra total de dados disponível, considerando as etapas de treinamento, validação e verificação

Estatísticas de desempenho do modelo 5 partes																				
Parte	Modelo	Registros	Treinamento						Validação						Verificação					
			NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE
1	m5_1_nni_3_quan_1000_rep_3_NS_723	1000	0,844	10,70	67,09	360,98	19,11	39,98	0,789	7,64	60,63	340,56	16,95	40,40	0,723	6,03	62,07	1026,59	16,04	43,07
2	m5_2_nni_3_quan_1500_rep_3_NS_757	1500	0,716	11,58	94,51	1196,43	28,99	76,20	0,643	11,59	119,96	1132,66	31,53	84,49	0,757	12,20	100,75	995,22	28,16	68,17
3	m5_3_nni_3_quan_800_rep_3_NS_596	800	0,654	11,63	162,62	882,26	38,29	99,30	0,720	12,87	145,77	843,80	35,44	86,11	0,596	12,69	143,30	1335,51	38,55	100,57
4	m5_4_nni_3_quan_2000_rep_3_NS_804	2000	0,744	8,32	117,66	961,50	33,15	91,71	0,838	7,19	112,14	802,30	28,02	72,02	0,804	5,22	122,25	1526,50	26,34	78,59
5	m5_5_nni_3_quan_1500_rep_3_NS_610	1500	0,678	17,33	191,17	1421,43	45,27	107,09	0,577	16,77	206,50	1341,05	49,78	121,86	0,610	17,44	211,16	1538,95	48,89	115,71

Descrição do nome do modelo: para o modelo "m5_1_nni_3_quan_1000_rep_3_NS_723" => m5_1: indica que os dados totais foram divididos em 5 partes (5 RNAs) e que esse modelo apresentado é a RNA desenvolvida para a parte 1 dos dados (RNA1); nni_3: indica que foram utilizados 3 neurônios na camada intermediária da RNA treinada; quan_1000: indica que o melhor desempenho da RNA foi obtido com 1000 dados para a série de treinamento; rep_3: indica que foram realizadas 3 inicializações para evitar a aleatoriedade dos dados iniciais da rede; NS_723: indica que o NS encontrado na verificação da rede foi igual a 0,723

Fonte: autora

Nas Figuras 27 a 29 estão representadas a turbidez observada e simulada em relação à reta de ajuste ideal (Figura 27a,e; Figura 28a,e e Figura 29a); o erro verificado entre os valores calculados e observados de turbidez (Figura 27b,f; Figura 28b,f e Figura 29b) e; o comportamento dos valores de turbidez calculados e observados, considerando os processos de treinamento (Figura 27c,g; Figura 28c,g e Figura 29c) e de verificação (Figura 27d,h; Figura 28d,h e Figura 29d) de cada uma das cinco partes em que a amostra total de dados foi subdividida para o desenvolvimento das RNAs.

Geralmente, os modelos de RNAs desenvolvidos mostraram-se capazes de representar a variação do comportamento da turbidez ao longo dos eventos, para cada uma das partes da subdivisão da amostra total de dados (Figura 27c,d,g,h; Figura 28c,d,g,h e Figura 29c,d).

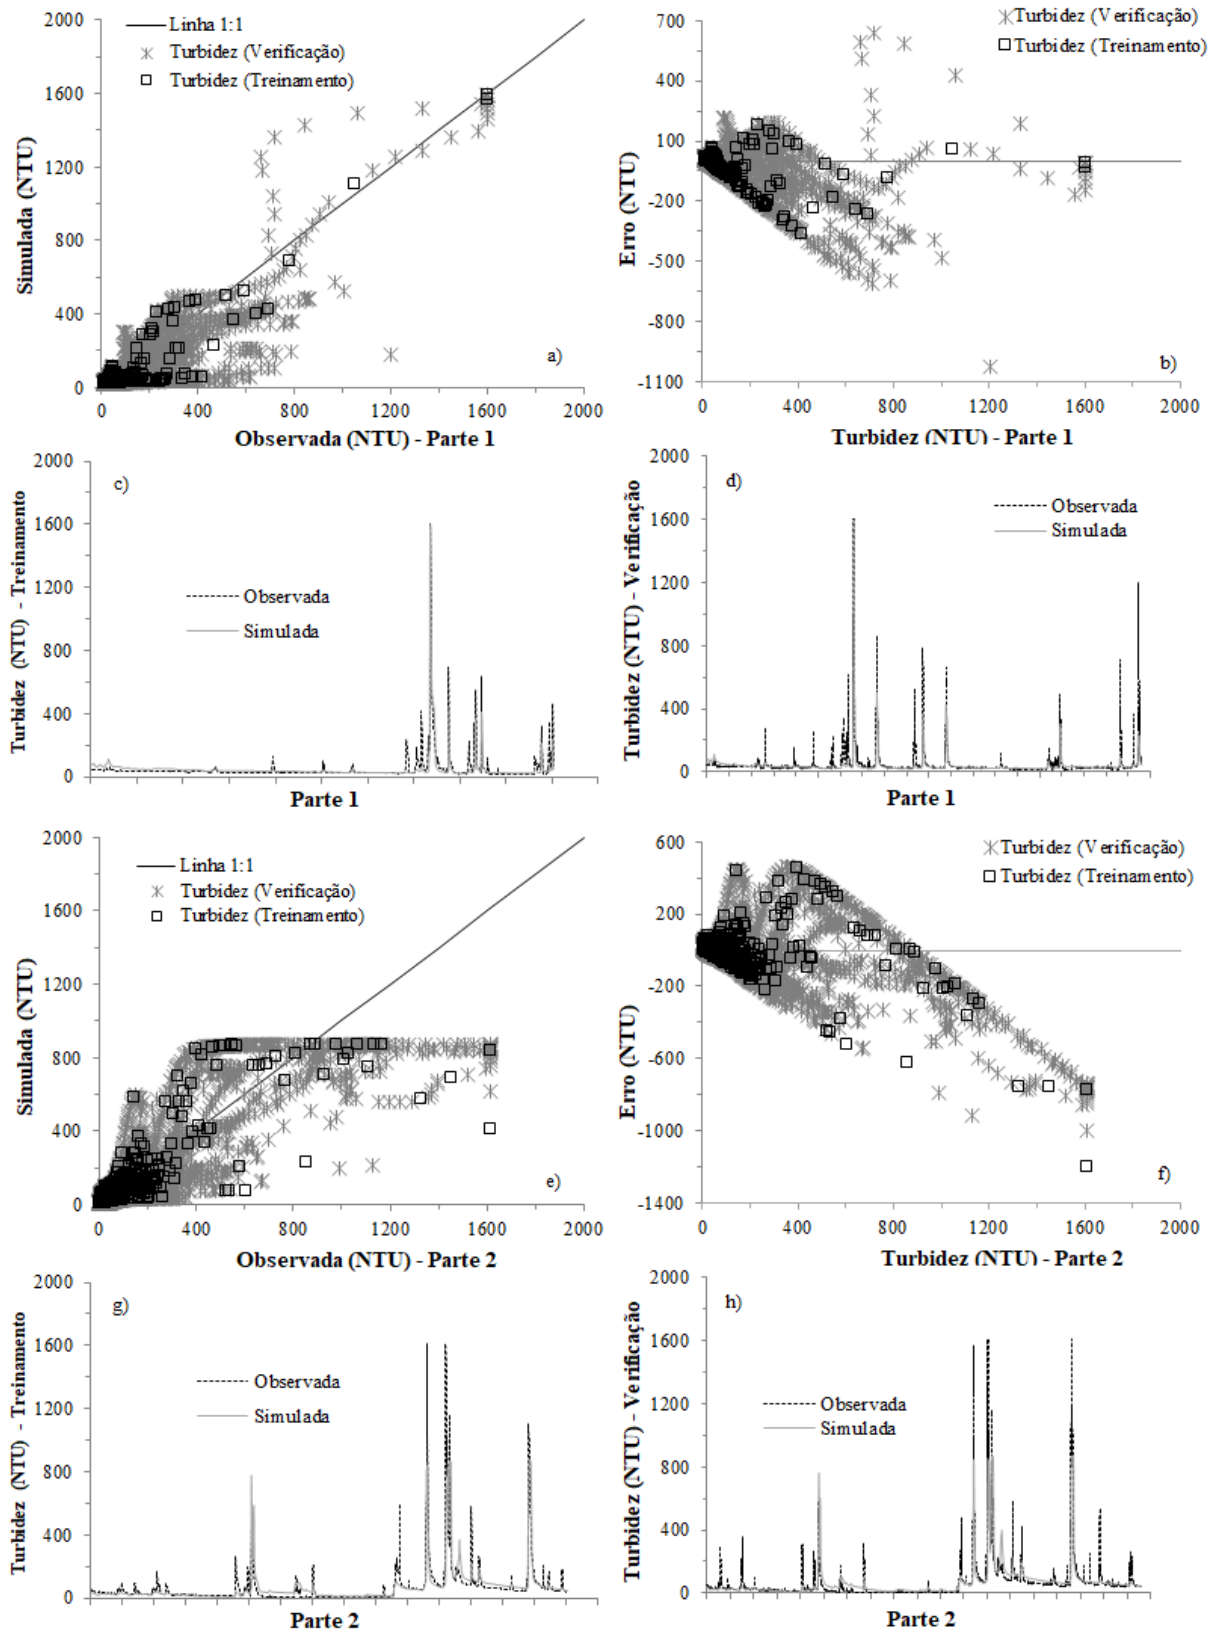
Entretanto, houve alguns problemas na representação dos picos de turbidez monitorados na bacia, os quais foram, muitas vezes, subestimados pelas redes desenvolvidas. Contudo, quando se analisa o total de dados simulados, em cada uma das partes treinadas, as RNAs desenvolvidas frequentemente apresentaram tendência à superestimativa dos valores de turbidez simulados em relação aos observados.

No processo de treinamento, as melhores relações entre os dados observados e simulados (melhor NS) foram verificadas para a parte 1 e 4 da amostra total; enquanto que na verificação, destacaram-se como melhores relacionadas as partes 2 e 4. Por outro lado, os piores resultados da relação dados observados x simulados foram percebidos para a RNA desenvolvida para a parte 3 da amostra total, tanto na etapa de treinamento quanto na etapa de verificação das redes (Tabela 30, Figura 27a,e; Figura 28a,e e Figura 29a).

Analisando-se os erros máximos e mínimos registrados entre os valores de turbidez observados e calculados para os processos de treinamento e de verificação das RNAs de cada parte da subdivisão dos dados, observou-se que os menores erros ocorreram para a parte 1 da subdivisão dos dados, seguida da RNA treinada para a parte 2. A maior variação dos erros foi verificada para a parte 5 da subdivisão da amostra total de dados (Figura 27b,f; Figura 28b,f e Figura 29b).

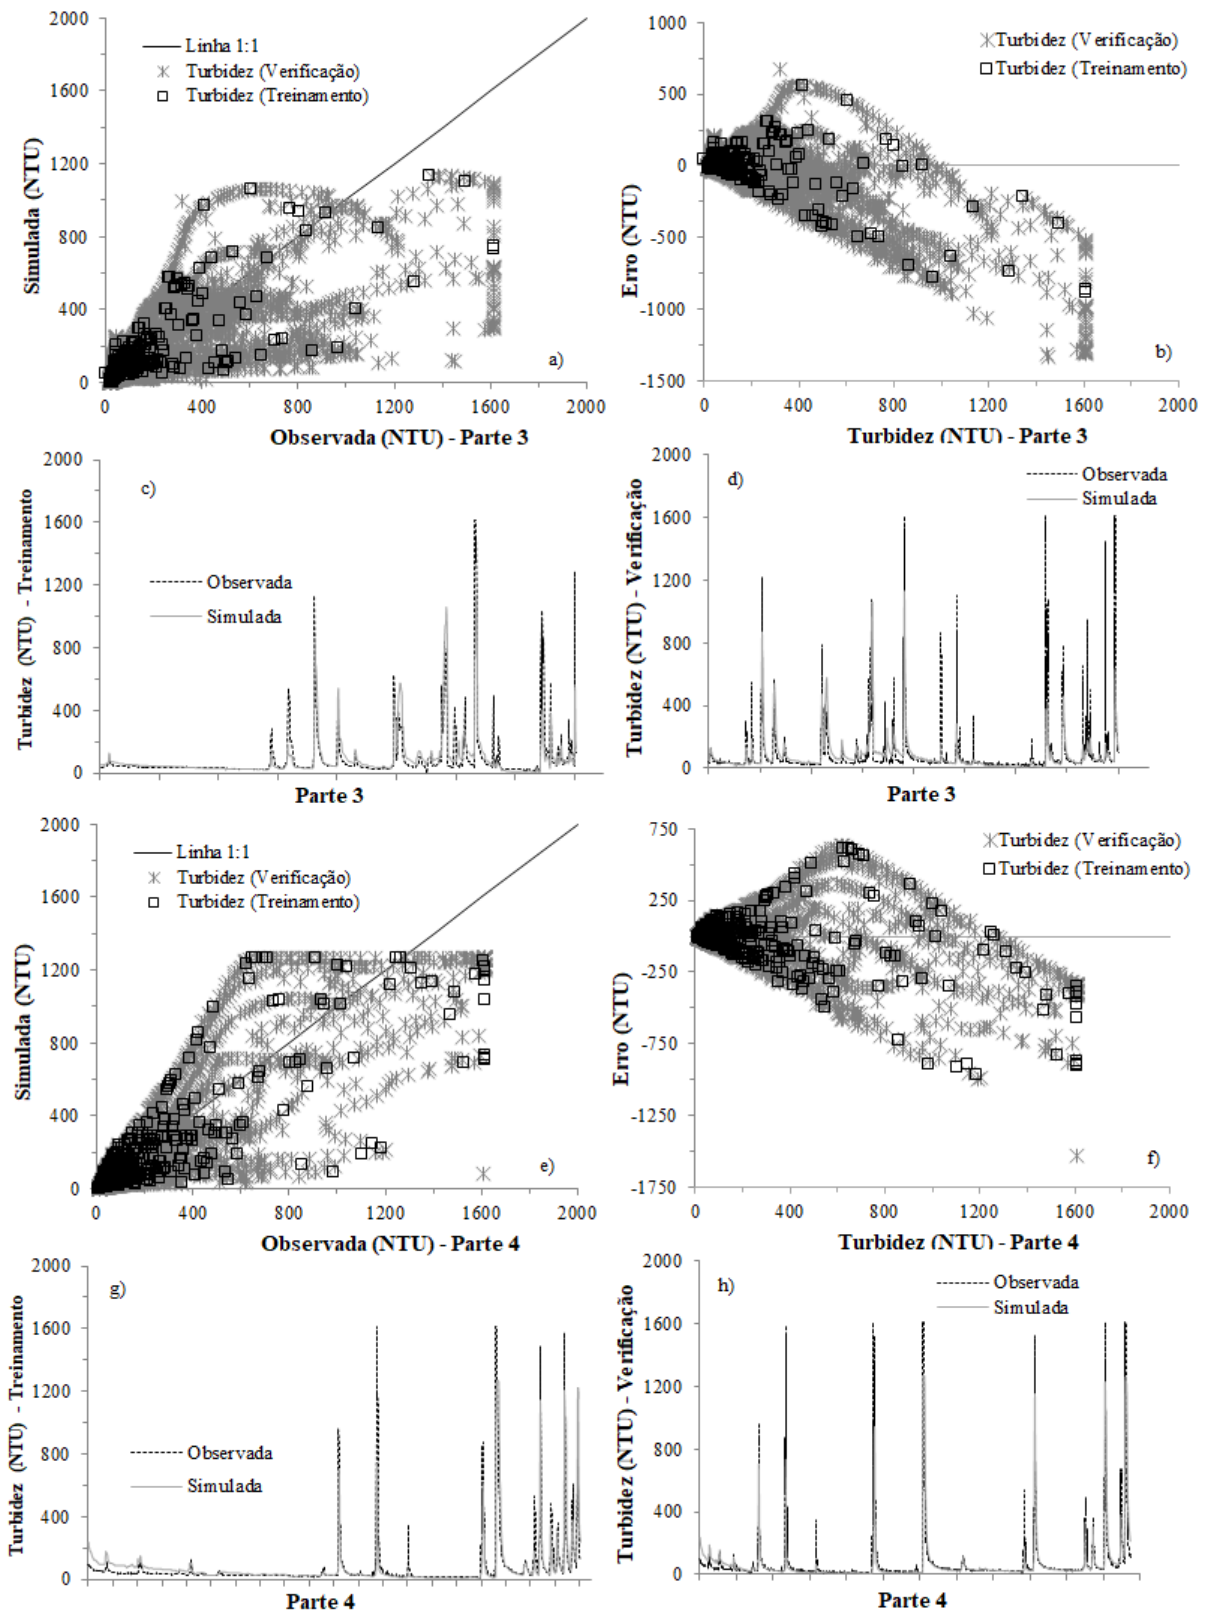
No entanto, ao se considerar o erro absoluto médio (EaM) e o erro mediano (Ea(50)), percebeu-se que o melhor desempenho das RNAs desenvolvidas esteve associado às partes que apresentaram melhor NS no treinamento e na verificação (partes 1, 2 e 4); condizendo com aquilo que foi verificado para as melhores relações de ajuste entre dados observados e simulados.

Figura 27 - Turbidez observada e simulada em relação à reta de ajuste ideal (a,e), erro verificado entre os valores calculados e observados de turbidez (b,f), e comportamento dos valores de turbidez calculados e observados; considerando os processos de treinamento (c,g) e de verificação (d,h) das partes 1 e 2 do total de 5 partes de divisão da amostra de dados disponível



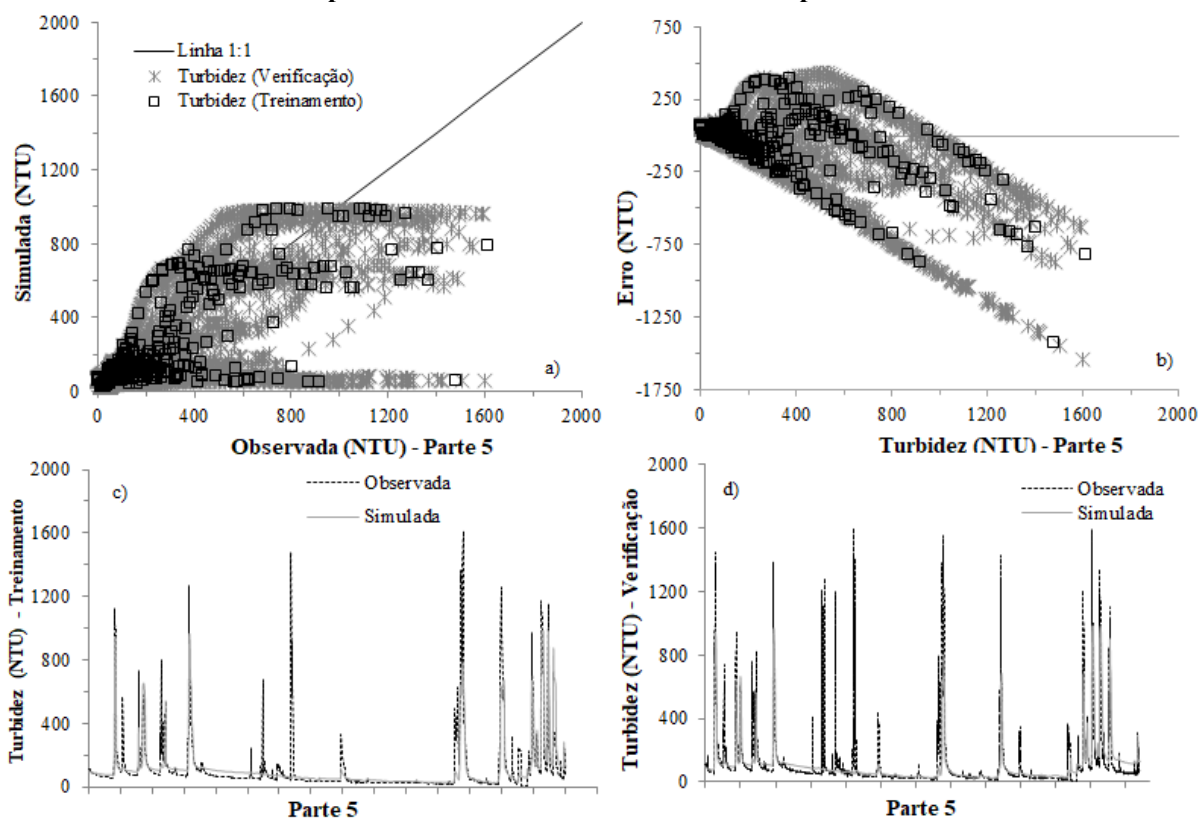
Fonte: autora

Figura 28 - - Turbidez observada e simulada em relação à reta de ajuste ideal (a,e), erro verificado entre os valores calculados e observados de turbidez (b,f), e comportamento dos valores de turbidez calculados e observados; considerando os processos de treinamento (c,g) e de verificação (d,h) das partes 3 e 4 do total de 5 partes de divisão da amostra de dados disponível



Fonte: autora

Figura 29 - Turbidez observada e simulada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados de turbidez (b), e comportamento dos valores de turbidez calculados e observados (c, d); considerando os processos de treinamento e de verificação da parte 5 do total de 5 partes de divisão da amostra de dados disponível



Fonte: autora

Na Tabela 31 são apresentadas as estatísticas dos dados de turbidez monitorados (total de dados, dados existentes e dados falhos), considerando o período compreendido entre 2013 e 2015, por ano e para a série total de dados disponíveis.

Tabela 31 - Estatísticas dos dados de turbidez monitorados (total de dados, dados existentes e dados falhos), considerando o período compreendido entre 2013 e 2015, por ano e para a série total disponível

Ano	Total de dados*	Dados existentes	Dados falhos		
			Nº de dados de 10 min	Nº de dias	% Anual
2013	50.475	28.143	22.332	155,08	44,24
2014	52.704	36.574	16.130	112,01	30,60
2015	52.973	49.983	2.990	20,76	5,64
2013-2015	156.152	114.700	41452	% Falhas período total	26,55
				% Dados sem falhas	73,45

* Contabilizados dados falhos e dados existentes

Fonte: autora

Para o período de monitoramento utilizado nessa pesquisa, entre os anos de 2013 e 2015, 26,55% dos registros da série total de dados de turbidez eram falhos, necessitando de preenchimento ou substituição das informações. Do período analisado, o ano de 2013

apresentou maior quantidade de dados falhos, com 44,24% de registros ausentes do total anual considerado. Já o ano de 2015 possuía o menor percentual de falhas nos registros anuais (5,65% do total do ano).

O maior período falho em 2013 decorreu do envio do sensor para reparo, o que se deu entre junho e outubro daquele ano. Por outro lado, no ano de 2014, o sensor despreendeu-se durante um evento de vazão elevada, em função de galhos transportados na calha do rio, o que também ocasionou uma falha significativa na série de turbidez, para os registros monitorados entre maio e junho desse ano. As demais falhas decorreram de outros problemas operacionais do sensor de turbidez, ou em razão de problemas na bateria que alimentava o sistema.

Na Tabela 32 são descritos, para cada ano, as datas de início e de fim dos períodos falhos; a informação do nível de água estar disponível ou falho nesse mesmo período; o modelo utilizado para preenchimento dos registros falhos (considerando as RNAs desenvolvidas para as partes 1 a 5 da amostra total) e; a quantidade de registros preenchidos por cada modelo.

Tabela 32 - Características dos períodos falhos e modelos empregados para o preenchimento das informações de turbidez para o período de 2013 a 2015

Ano a ser preenchido: 2013					
Falhas início	Falhas fim	Nível	Modelo usado para o preenchimento	Dias falhos	Nº de registros falhos
17/02/2013 22:50:00	18/02/2013 15:30:00	Não falho	Parte 1: m5_1_nni_3_quan_1000_rep_3_NS_723	0,69	101,00
31/05/2013 00:00:00	31/10/2013 10:00:00	Não falho	Parte 1: m5_1_nni_3_quan_1000_rep_3_NS_723	153,42	22092,00
18/12/2013 10:00:00	19/12/2013 09:00:00	Não falho	Parte 1: m5_1_nni_3_quan_1000_rep_3_NS_723	0,96	49,00
Ano a ser preenchido: 2014					
Falhas início	Falhas fim	Nível	Modelo usado para o preenchimento	Dias falhos	Nº de registros falhos (10 min)
04/03/2014 04:30:00	25/05/2014 23:50:00	Não falho	Parte 2: m5_2_nni_3_quan_1500_rep_3_NS_757	82,81	12070,00
06/06/2014 03:30:00	25/06/2014 15:00:00	Não falho	Parte 2: m5_2_nni_3_quan_1500_rep_3_NS_757	19,48	2806,00
13/10/2014 12:00:00	15/10/2014 11:40:00	Não falho	Parte 3: m5_3_nni_3_quan_800_rep_3_NS_596	1,99	287,00
20/10/2014 02:00:00	26/10/2014 19:10:00	Não falho	Parte 3: m5_3_nni_3_quan_800_rep_3_NS_596	6,72	967,00
Ano a ser preenchido: 2015					
Falhas início	Falhas fim	Nível	Modelo usado para o preenchimento	Dias falhos	Nº de registros falhos (10 min)
05/02/2015 11:40:00	08/02/2015 17:10:00	Não falho	Parte 4: m5_4_nni_3_quan_2000_rep_3_NS_804	3,2	467,00
30/11/2015 23:50:00	04/12/2015 11:20:00	Falho*	Parte 5: m5_5_nni_3_quan_1500_rep_3_NS_610	3,5	502,00
05/12/2015 14:30:00	16/12/2015 14:50:00	Não falho	Parte 5: m5_5_nni_3_quan_1500_rep_3_NS_610	11,0	2021,00

* Dados falhos preenchidos por modelos gerados

Fonte: autora

Das cinco RNAs desenvolvidas para as partes 1 a 5 da amostra total de dados de turbidez, a RNA rn5_1_nni_3_quan_1000_rep_3_NS_723, desenvolvida para a parte 1 da amostra total disponível, foi a mais acionada para a execução do preenchimento dos dados falhos, sendo utilizada para recuperar 22.242 dados com período de registro de 10 em 10 min. A segunda RNA mais empregada foi a rn5_2_nni_3_quan_1500_rep_3_NS_757, usada para o preenchimento de 14.876 registros falhos. O terceiro modelo mais utilizado foi a rede treinada para a parte 5 da amostra total de dados (rn5_5_nni_3_quan_1500_rep_3_NS_610); tendo sido usada para preencher 2.523 registros falhos de 10 minutos.

As RNAs mais utilizadas no preenchimento das informações de turbidez ausentes mostraram desempenho “Muito Bom” (parte 2); “Bom” (parte 1) e “Satisfatório” (parte 5), no processo de verificação, conforme critério estabelecido por Moriasi et al. (2007). Por outro lado, a RNA com o pior dos desempenhos (RNA desenvolvida para a parte 3 da amostra total – NS=0,596) foi empregada para preenchimento de 1.254 dados falhos, sendo o quarto modelo mais empregado, entre um total de cinco RNAs disponíveis para o preenchimento das falhas.

Dos 41.452 registros de turbidez preenchidos, 502 dados (1,21%) também estavam falhos na série de níveis de água utilizada, ou seja, para esses dados foi necessário primeiro aplicar o modelo para preenchimento de níveis de água para, na sequência, utilizar as RNAs para estimativa da turbidez com emprego dos dados de níveis de água já preenchidos. O uso conjunto dos dois modelos de RNAs, para preenchimento dessas duas variáveis, implica maior incerteza na estimativa dos dados que serão, posteriormente, utilizados na modelagem hidrossedimentológica com o modelo SWAT.

Em termos gerais, os modelos de RNAs desenvolvidos para o preenchimento das falhas de turbidez na bacia do Taboão representaram uma alternativa viável para o preenchimento das lacunas existentes e; conseqüentemente, para a obtenção de séries contínuas de dados; possibilitando o uso posterior dessas informações para estimativas da CSS. As estatísticas de desempenho foram apontadas, usualmente, como satisfatórias a boas e, em alguns casos, muito boas; mesmo utilizando uma escala de tempo menor do que a reportada em outros estudos que também empregaram RNAs para estimativa da turbidez, trabalhando, todavia, com uma escala de tempo frequentemente maior.

Najah et al. (2013), por exemplo, aplicaram RNAs, do tipo perceptron multicamadas e rede de base radial, para a previsão de parâmetros de qualidade da água (sólidos totais dissolvidos, condutividade elétrica e turbidez), na bacia do rio Johor e seu tributário (Malásia). Os autores utilizaram dados coletados entre 1998 e 2002 para o treinamento (30 amostras) e a

verificação das redes (4 amostras), empregando sólidos totais dissolvidos como entrada da RNA desenvolvida para a estimativa da turbidez. O coeficiente NS observado para a rede perceptron multicamadas foi igual a 0,65 e 0,85 para o canal principal e para o rio tributário, respectivamente; e, quando empregada a rede de base radial, elevou-se para 0,80 e 0,89 no canal principal e no tributário, respectivamente.

Já Yang et al. (2014) construíram um modelo de previsão da turbidez diária e um sistema de aviso, no domínio da fonte de água de Taipei (cidade de Taipei), a partir de informações de precipitação acumulada de 1 e 2 dias, monitoradas em seis locais. O modelo RNA desenvolvido mostrou bons resultados, alcançando um Coeficiente de Correlação de Pearson (R^2) igual a 0,73 no treinamento e 0,71 na verificação da rede.

Kim e Seo (2015), por sua vez, utilizaram RNAs para prever diversas variáveis de qualidade da água (entre as quais a turbidez), no rio Nakdong (Coréia), em um passo de tempo à frente. O coeficiente de correlação (R) obtido para a previsão da turbidez foi baixo (0,58), sendo justificado em função de um conjunto de dados altamente variável. Não obstante, quando os dados foram particionados em várias classes (semelhante ao executado nesse estudo), por métodos de agrupamento (*cluster*) que consideraram os padrões desses dados, o desempenho dos modelos melhorou significativamente, atingindo um R igual a 0,88.

Tabari e Talae (2015) analisaram a eficiência de modelos de RNAs (perceptron multicamadas e rede de base radial), com o objetivo de recuperar os valores ausentes de 13 parâmetros de qualidade da água no rio Maroon (Irã), entre os quais a turbidez. As entradas utilizadas nos modelos foram os demais parâmetros que não estavam falhos para o tempo em que se desejava preencher os dados. Os resultados mostraram-se insatisfatórios para a estimativa da turbidez, quando utilizado por base os demais parâmetros de qualidade disponíveis. Encontrou-se coeficiente R variando entre -0,056 e 0,482 para a rede perceptron e; entre 0,085 e 0,343 para rede de base radial.

4.5 Estimativa dos dados de CSS: análise das funções explícitas entre nível de água, turbidez e CSS

As funções explícitas, apresentadas a seguir, foram ajustadas pelo método quase-Newton BFGS, com uso da função `fminunc` do Matlab R2010a, com as condições de finalização representadas pelo limite de 100.000 iterações, e pelas variações máximas admitidas, tanto da função objetivo quanto dos parâmetros, de 1×10^{-7} . Em todas as aplicações, o procedimento foi

interrompido após ter sido encontrado um ponto de mínimo, tendo sido atingido o limite da variação da função objetivo ou o limite da variação dos parâmetros.

Na Tabela 33 são mostrados os resultados das estatísticas das equações que relacionam turbidez, nível de água e CSS. Os melhores resultados de ajuste, para todas as variáveis testadas, foram verificados quando empregado ajuste do tipo não linear.

Nas Figuras 30 a 32 são mostradas as relações de ajuste entre turbidez x CSS (Figura 30a) e nível de água x CSS (Figura 31a), além dos valores de CSS observada e simulada em relação à reta de ajuste ideal (Figura 30b, Figura 31b, Figura 32a) e; os erros verificados entre os valores de CSS calculados e observados (Figura 30c, Figura 31c, Figura 32b). Além disso, também são apresentados o comportamento dos valores de CSS calculados e observados ao longo dos eventos analisados (junho de 2013 e outubro de 2015), para a série de treinamento (Figura 30d, Figura 31d, Figura 32c) e de verificação (Figura 30e, Figura 31e, Figura 32d); considerando os melhores modelos ajustados para a estimativa da CSS em função da turbidez e do nível de água, isoladamente e para as duas variáveis usadas em conjunto, respectivamente.

A melhor equação ajustada para a estimativa da CSS tendo por base somente dados de nível de água foi do tipo potencial, com $NS=0,581$ (Figura 31a), sendo esta a equação com estatística de melhor desempenho em relação aos demais ajustes testados para essa variável. Quando se consideram as relações de ajuste para estimativa da CSS utilizando somente informações de turbidez, a eficiência dos modelos ajustados aumenta bastante. O desempenho dessas equações, baseadas exclusivamente em dados de turbidez, foi muito superior àqueles que fazem uso somente do nível de água no rio. O melhor ajuste para a turbidez foi determinado para uma relação do tipo exponencial, sendo $NS=0,911$ (Figura 30a).

De fato, as equações ajustadas demonstram a não linearidade e a complexidade dos fenômenos de transporte de sedimentos. Isso ocorre porque a quantidade de sedimentos transportada por um determinado escoamento (nível de água) é dependente da atuação de diversos fatores, entre os quais: i) as precipitações e condições antecedentes de umidade do solo, que podem favorecer a ocorrência dos processos erosivos na bacia; ii) a disponibilidade de fontes de sedimentos na bacia nas diferentes épocas do ano, conforme características climáticas e práticas de manejo agrícola adotadas; iii) a existência de depósito de sedimentos no leito do rio, que podem entrar em suspensão, de acordo com as características do escoamento; iii) a ocorrência de erosões na margem e no leito do canal; etc. Como todos esses fatores afetam diretamente a turbidez, essa variável, muitas vezes, mostra-se mais bem relacionada com a CSS do que o nível de água.

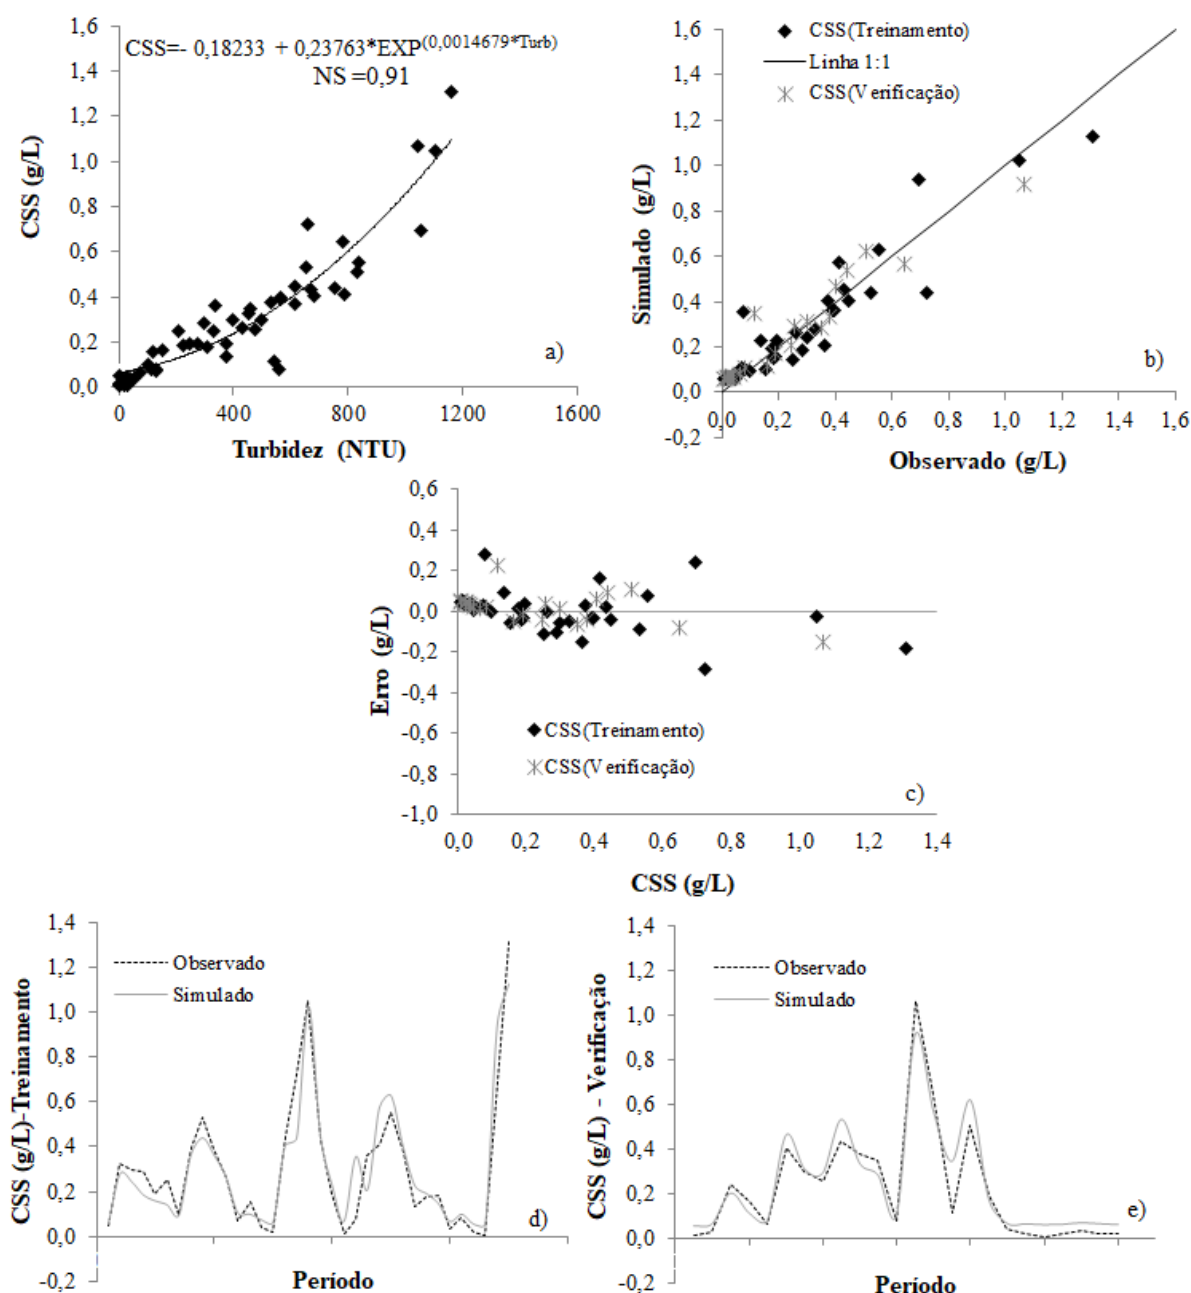
Tabela 33 - Resumo das estatísticas dos modelos ajustados para estimativa da CSS tendo por base informações de nível de água e turbidez

CSS=Função (Nível de água)						
Função	Estatísticas de verificação					
	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS
CSS = - 0,19656 + 0,28634*NA	0,05	0,35	0,66	0,10	0,16	0,5790
CSS = 0,11103 *NA ^{1,6911}	0,06	0,36	0,67	0,10	0,16	0,5712
CSS = - 0,16611 + 0,2552*NA^{1,0812}	0,05	0,35	0,66	0,10	0,16	0,5808
CSS = 0,059324*exp ^(0,86231*NA)	0,08	0,39	0,70	0,12	0,18	0,5111
CSS = 27,4503 - 27,6504*exp ^(-0,0105391*NA)	0,06	0,35	0,66	0,10	0,16	0,5787
CSS= - 0,20097 + 0,29268*NA - 0,0019033*NA ²	0,06	0,35	0,66	0,10	0,16	0,5786
CSS=Função(Turbidez)						
Função	Estatísticas de verificação					
	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS
CSS= - 0,023363 + 0,00081061*Turb	0,03	0,26	0,3	0,06	0,1	0,8420
CSS= 7,7277x10 ⁻⁵ *Turb ^{1,3469}	0,03	0,2	0,26	0,06	0,09	0,8840
CSS= 0,070342 + 8,7881x10 ⁻⁶ *Turb ^{1,65}	0,05	0,18	0,24	0,06	0,08	0,8932
CSS= 0,10228 *exp ^(0,0021018*Turb)	0,08	0,17	0,21	0,07	0,08	0,8868
CSS= - 0,18233 + 0,23763*exp^(0,0014679*Turb)	0,04	0,18	0,23	0,06	0,08	0,9108
CSS= 0,00025988 + 0,00046911*Turb + 3,7922x10 ⁻⁷ *Turb ²	0,03	0,19	0,25	0,05	0,08	0,8959
CSS=Função(Turbidez, Nível de água)						
Função	Estatísticas de verificação					
	Ea(50)	Ea(95)	Ea(Max)	EaM	RMSE	NS
CSS= - 0,048529*NA + 0,00093635*Turb	0,04	0,23	0,32	0,07	0,10	0,8442
CSS= - 0,0069246*NA ^{2,7552} + 8,6469X10 ⁻⁵ *Turb ^{1,3478}	0,04	0,18	0,28	0,06	0,09	0,8817
CSS=0,076428 - 0,01033*NA ^{1,2242} + 1,2587x10 ⁻⁵ *Turb ^{1,6024}	0,05	0,18	0,25	0,07	0,08	0,8915
CSS= - 0,047056 *NA^{-1,9817} + 0,12435*exp^(0,001917 *Turb)	0,04	0,18	0,22	0,05	0,07	0,9203
CSS= - 0,091023 - 0,090998*NA ^{0,01267} + 0,23769*exp ^(0,0014684 *Turb)	0,04	0,18	0,23	0,06	0,08	0,9104
CSS= - 0,00035517*exp ^(2,3318*NA) + 9,9912x10 ⁻⁵ *Turb ^{1,3327}	0,04	0,2	0,31	0,06	0,09	0,8788
CSS= 0,10219 - 0,013811*exp ^(0,72109*NA) + 1,0139x10 ⁻⁵ *Turb ^{1,6404}	0,06	0,16	0,26	0,07	0,08	0,8881
CSS= - 0,19189*exp ^(0,019631*NA) + 0,25031*exp ^(0,0014348*Turb)	0,04	0,18	0,23	0,06	0,08	0,9096
CSS= - 0,092172 - 0,092151*exp ^(0,0094966*NA) + 0,24039*exp ^(0,0014605*Turb)	0,04	0,18	0,23	0,06	0,08	0,9105
CSS=1,752x10 ⁻¹² + 3,8118x10 ⁻¹² *NA + 8,6434x10 ⁻¹² *NA ² + 1,1967x10 ⁻⁹ *Turb + 1x10 ⁻⁶ *Turb ²	0,05	0,18	0,18	0,07	0,09	0,8796

Letras em negrito: representa o melhor ajuste entre as variáveis no processo de verificação NA: nível de água Turb: Turbidez CSS: concentração de sedimentos suspensos

Fonte: autora

Figura 30 - Relações de ajuste entre CSS e turbidez (a), CSS observada e calculada em relação ao ajuste ideal (b), erro verificado entre os valores calculados e observados da CSS (c), e comportamento dos valores calculados e observados para a série de treinamento (d) e de na verificação (e), respectivamente; considerando o melhor modelo de ajuste baseado na variável de entrada turbidez

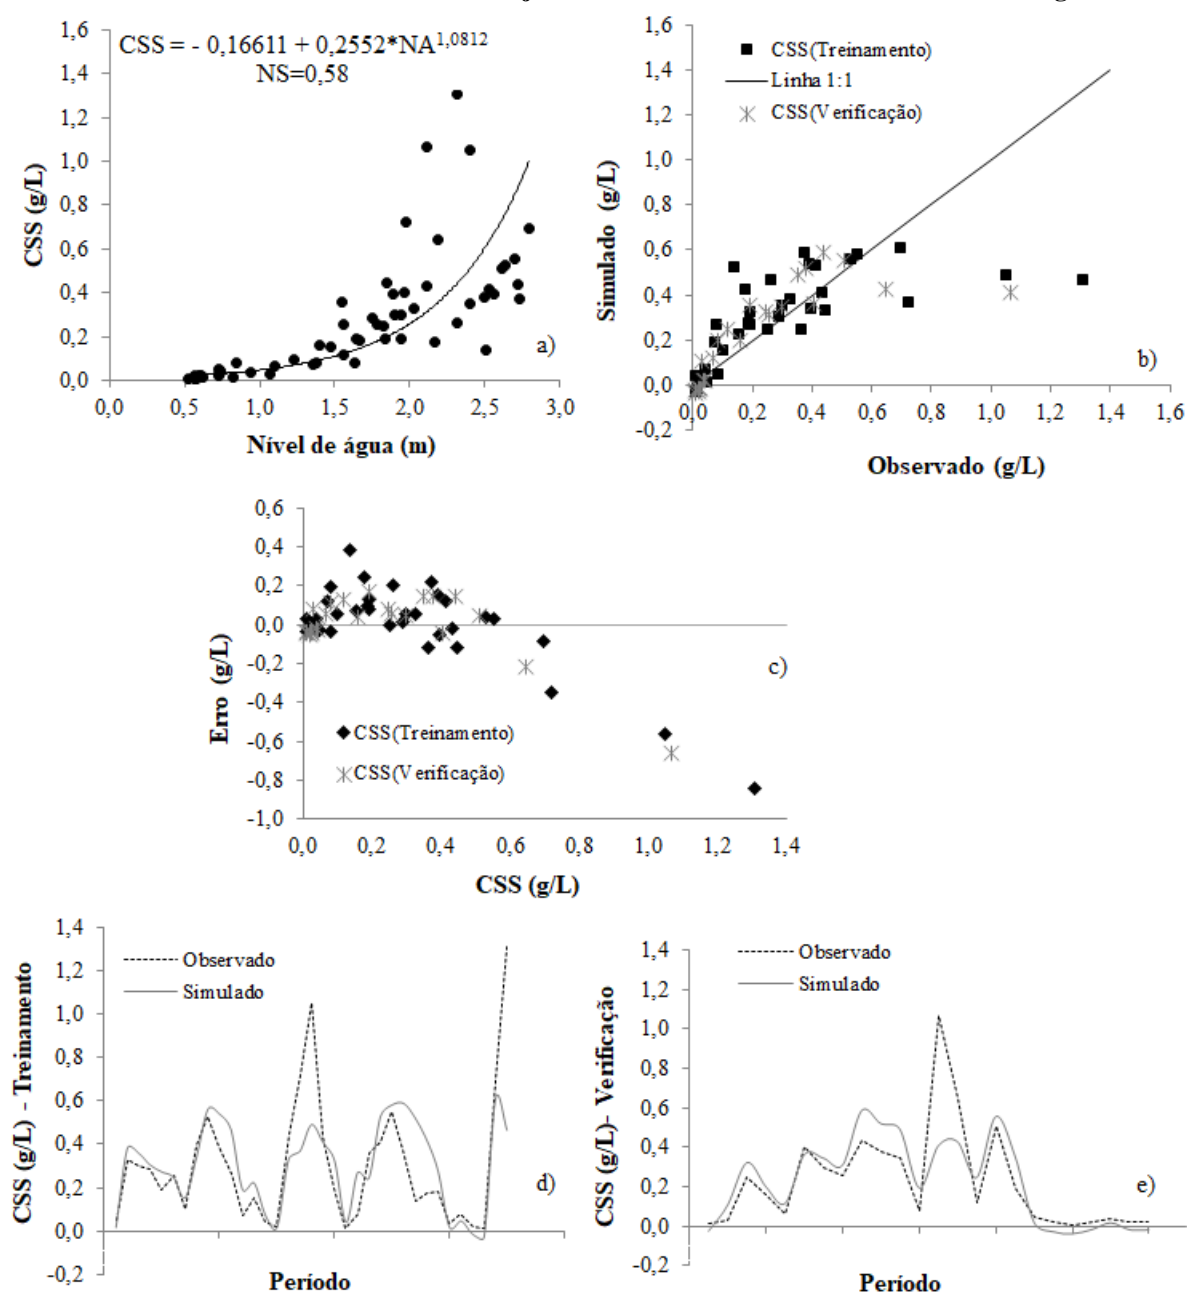


Fonte: autora

O modelo que utilizou conjuntamente as duas variáveis (nível de água e turbidez) e equação não linearizável, resultou em pequena melhoria da eficiência ($NS=0,920$) na estimativa da CSS, em relação à equação ajustada somente para os dados de turbidez ($NS=0,910$). Esse ajuste, na prática, resultou de uma combinação dos dois melhores modelos definidos anteriormente para as relações nível de água x CSS, e turbidez x CSS; representando, portanto,

uma junção da relação tipo potencial (melhor ajuste definido para a variável nível de água) com a relação tipo exponencial (melhor relação ajustada para a variável turbidez).

Figura 31 - Relações de ajuste entre CSS e nível de água (a), CSS observada e calculada em relação ao ajuste ideal (b), erro verificado entre os valores calculados e observados da CSS (c), e comportamento dos valores calculados e observados para a série de treinamento (d) e de verificação (e), respectivamente; considerando o melhor modelo de ajuste baseado na variável de entrada nível de água

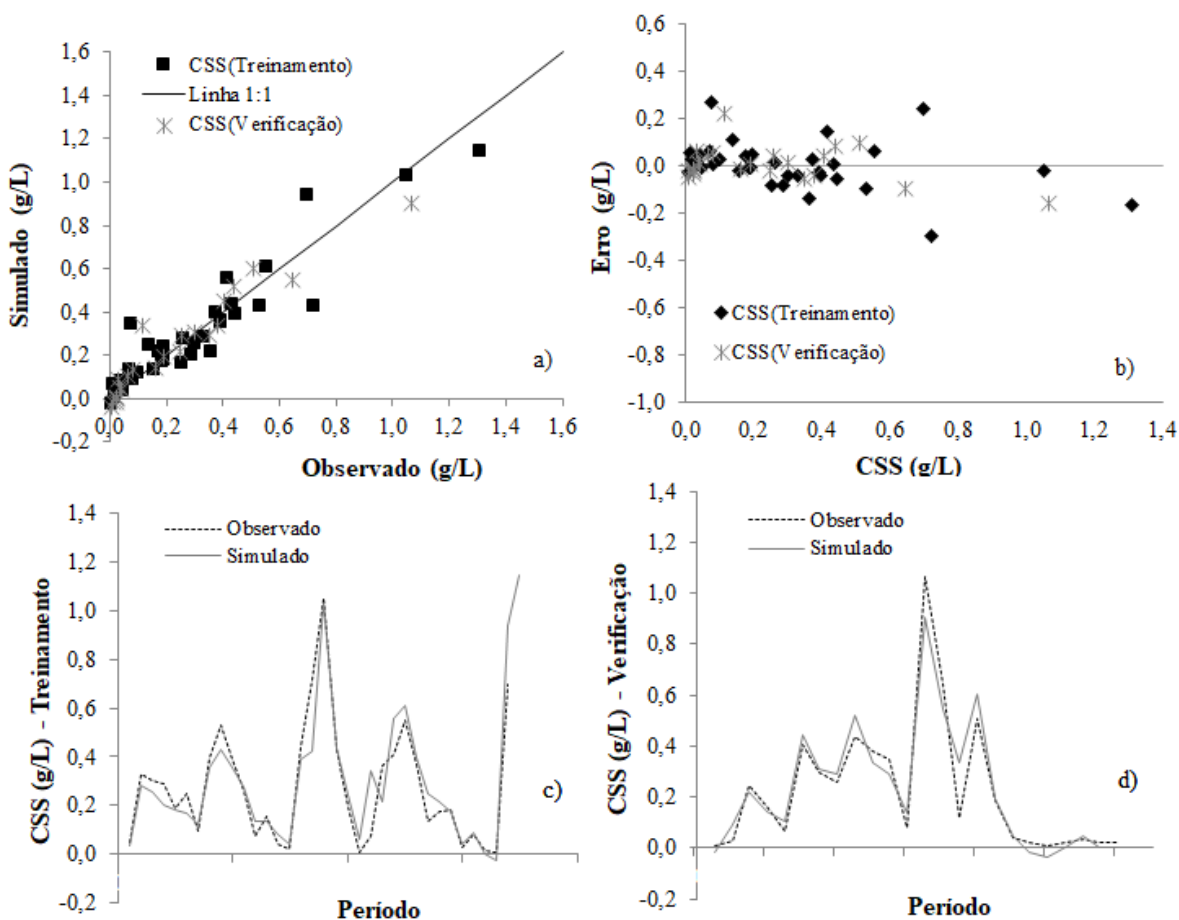


Fonte: autora

Observaram-se melhores resultados de previsão da CSS quando se utilizou o modelo baseado nas informações de turbidez, com estatísticas de desempenho significativamente maiores, quando comparadas ao ajuste que empregou somente dados de nível de água. As

particularidades do comportamento nível de água x CSS já discutidas anteriormente, entre elas o fenômeno de histerese, resultaram em um ajuste pouco satisfatório entre a CSS e o nível de água, quando foram utilizadas as técnicas tradicionais da modelagem hidrodinâmica (Figura 31a); caracterizando uma relação não linear de complexidade elevada.

Figura 32 - CSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados para a série de treinamento (c) e de verificação (d), respectivamente; considerando o melhor modelo de ajuste baseado nas variáveis de entrada turbidez e nível de água



Fonte: autora

Por outro lado, as maiores CSS foram sempre relacionadas aos maiores valores de turbidez (Figura 21a), gerando melhores ajustes da relação turbidez x CSS (Figura 30a). Entretanto, há que se considerar que essa relação também se caracteriza por um comportamento não linear, sendo consideravelmente afetada pelo tamanho da partícula de sedimento transportado em cada um dos regimes hidrológicos atuantes (SARI, CASTRO e KOBAYAMA, 2015).

De maneira geral, tanto o modelo fundamentado em informações de turbidez quanto o modelo que tem por base dados de nível de água conseguiram representar a variação geral do

comportamento da CSS ao longo do tempo, na série de treinamento (Figura 30d; Figura 31d) e de verificação (Figura 30e; Figura 31e); embora tenha ocorrido pequena tendência à superestimativa dos picos de CSS, com maiores erros na determinação dos extremos, observada para o modelo que empregou somente dados de nível de água (Figura 30d,e; Figura 31d,e).

No entanto, o ajuste entre a CSS observada e a calculada foi melhor para o modelo que utilizou a turbidez como medida indireta da CSS (Figura 30b; Figura 31b), apresentando melhor distribuição dos erros em torno do eixo zero e, portanto, menores discrepâncias na estimativa da CSS, com alguns valores muito próximos da reta de ajuste ideal, especialmente para CSS inferiores a 0,5 g/L. Entretanto, houve tendência a subestimativa dos valores de CSS superiores a 0,5 g/L (Figura 30c).

Já o modelo baseado no nível de água apresentou erros maiores, sobretudo, para as CSS mais elevadas, sendo as maiores discrepâncias observadas para CSS superiores a 0,5 g/L (Figura 32c), que foram subestimadas pelo modelo. O modelo ajustado mostrou-se, portanto, inadequado, na proporção em que pode haver uma grande limitação na aplicabilidade desse ajuste baseado no nível de água, já que a maioria dos sedimentos é transportada durante eventos de cheia (elevado nível de água), onde foram verificados os maiores erros no ajuste estabelecido.

Quando se considerou o modelo ajustado com base nas informações conjuntas de nível de água e turbidez (modelo nível de água-turbidez x CSS) percebeu-se uma pequena melhoria nas estatísticas de desempenho da série de verificação do ajuste obtido. O ajuste entre os dados de CSS observados e calculados (Figura 32a) foi mais adequado, com uma distribuição mais homogênea dos erros (Figura 32b) em torno do eixo zero, em comparação aos modelos que utilizam como entrada a turbidez e o nível de água, isoladamente. Esse modelo também conseguiu representar muito bem o comportamento geral da variação da CSS ao longo do tempo, tanto para a série de treinamento quanto para a de verificação (Figura 32c,d), com boa estimativa dos valores de CSS e boa distribuição entre os valores subestimados e superestimados pela equação ajustada.

Para quaisquer dos modelos escolhidos, os maiores erros na estimativa da CSS foram observados para valores de CSS maiores do que 5 g/L, correspondentes a níveis de água e turbidez mais elevados; sendo, nesse caso, mais frequente a ocorrência da superestimativa da CSS calculada para a série de verificação; à exceção do modelo baseado nas duas entradas conjuntas (nível de água e turbidez), em que houve equivalência entre valores de CSS subestimados e superestimados.

4.6 Estimativa da CSS utilizando RNAs sem emprego de recursos para evitar o superajustamento (Modelo_0)¹⁵: modelo Nível de água – Turbidez x CSS

No processo de treinamento da rede sem utilização da metodologia de treinamento e configuração proposta, o modelo foi treinado cinco vezes, com 200.000 ciclos em cada repetição. Foi escolhido o treinamento que correspondeu ao valor mediano da estatística de desempenho no treinamento, entre as repetições realizadas, a fim de se evitar os treinamentos com desempenhos extremos, melhores ou piores.

Na Figura 33 é apresentada a relação de ajuste entre os dados de CSS observados e calculados (a); o erro verificado entre os valores calculados e observados da CSS (b); e o comportamento dos valores de CSS calculados e observados (c), considerando as séries de treinamento e de verificação da RNA desenvolvida sem o emprego de recursos para evitar o superajustamento.

O modelo selecionado (Modelo_0) mostrou excelente desempenho durante o processo de treinamento da rede, explicando muito bem o comportamento da CSS ao longo do tempo (Figura 33c). O NS observado foi igual a 0,995 e as demais estatísticas, em g/L, foram: Ea(50) de 0,01, Ea(95) igual a 0,05, Ea(Max) de 0,05, EaM igual a 0,02 e RMSE igual a 0,021. O ajuste dos dados observados e calculados no treinamento foi muito satisfatório, com a maioria dos valores simulados próximos do ajuste ideal (Figura 33a). Os erros na saída da rede (Ea) foram muito pequenos, bem distribuídos e próximos do eixo zero (Figura 33b), indicando excelente ajuste da RNA na fase de treinamento.

Entretanto, ao se analisar a série de verificação da rede, observou-se um decaimento significativo de seu desempenho (NS=0,788), piorando o ajuste dos dados de CSS simulados em relação aos observados (Figura 33a), e reduzindo a representatividade do comportamento da CSS ao longo do tempo (Figura 33c,d), com erros maiores na representação dos picos da CSS estimada.

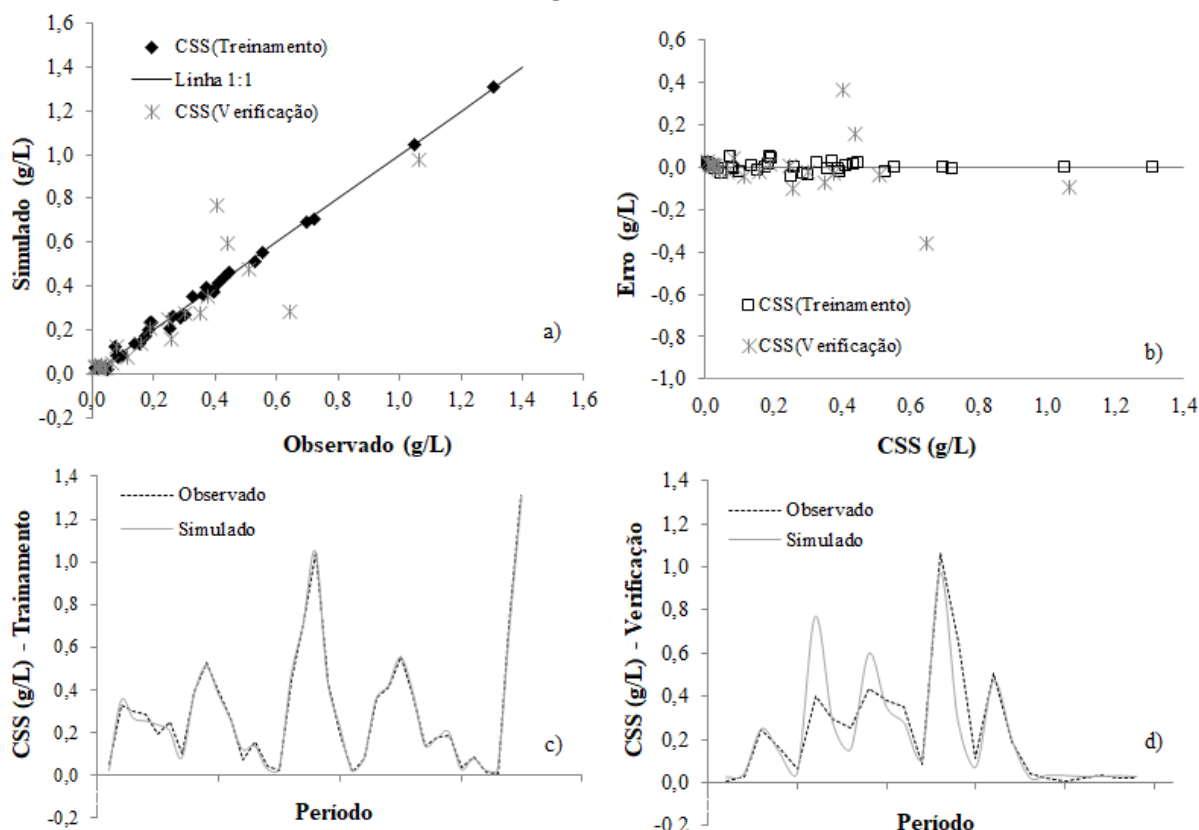
Os erros na saída da rede também aumentaram, apresentando uma distribuição mais variável em relação à série utilizada para treinamento, sobretudo para CSS acima de 0,3 g/L (Figura 33b). O erro absoluto médio (EaM) aumentou para 0,06 e o Ea(50) foi igual a 0,02, com Ea(95) de 0,36, Ea(Max) elevando-se para 0,37 e RMSE igual a 0,116. Esses resultados

¹⁵ Texto construído com base no artigo:

SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017. <https://doi.org/10.1007/s11269-017-1785-4>

demonstraram que a rede perdeu sua capacidade de generalização (capacidade de estimativa futura de novos dados), devido à ocorrência de superajustamento durante seu processo de treinamento, o que desaconselha sua aplicação futura para estimativa da CSS.

Figura 33 - CSS observada e calculada em relação à função de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados, considerando os processos de no treinamento (c) e na verificação (d) do Modelo_0 para as entradas nível de água e turbidez



Fonte: autora

4.7 Estimativa da CSS utilizando RNAs com o método proposto: modelo Nível de água-Turbidez x CSS (Modelo_1 e Modelo_2)¹⁶, modelo Nível de água x CSS (NívCSS_1 e NívCSS_2) e modelo Turbidez x CSS (TurbCSS_1 e TurbCSS_2)

Todos os treinamentos de redes neurais realizados com esse método foram feitos com cinco repetições, que foram suficientes para conferir estabilidade aos resultados, e com o máximo de 200.000 ciclos de treinamento cada, considerado suficiente como condição secundária de finalização.

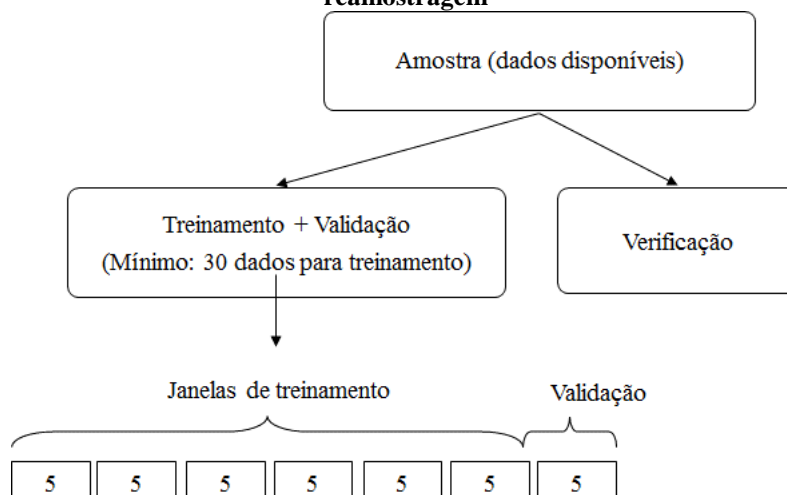
¹⁶Texto construído com base no artigo:

SARI, V.; CASTRO, N.M dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017. <https://doi.org/10.1007/s11269-017-1785-4>

Os 59 registros disponíveis para a pesquisa foram divididos em registros para o treinamento (35) e para a verificação final (24), sendo que estes últimos não podem participar de nenhuma forma dos procedimentos de definição da complexidade ou dos procedimentos de treinamento da rede neural.

O número de partições e de registros em cada partição, para a validação com reamostragem, foram definidos para atender à condição de restarem, a cada treinamento, pelo menos 30 registros; resultando sete partições com cinco registros cada, selecionados por amostragem sistemática (Figura 34).

Figura 34 - Divisão dos dados disponíveis para a aplicação do treinamento com validação por reamostragem



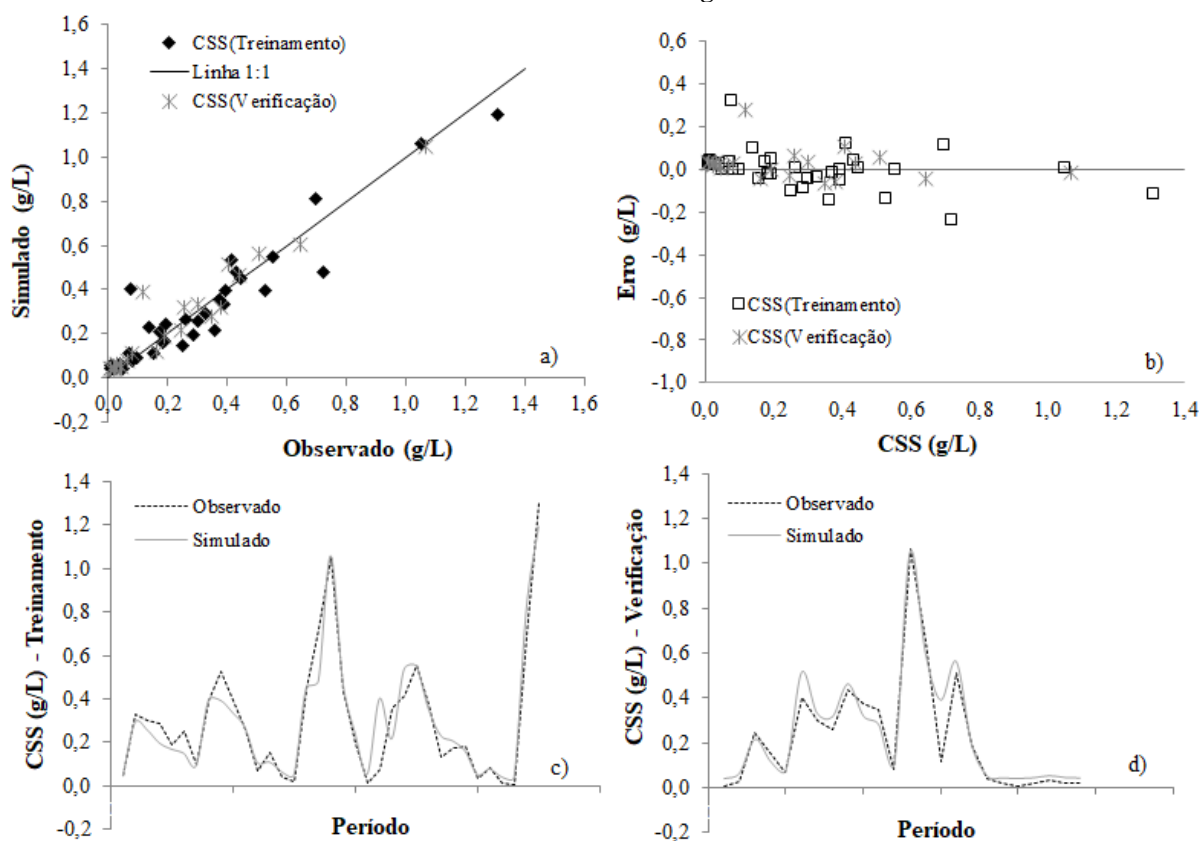
Fonte: autora

A primeira etapa do método proposto constituiu-se da pesquisa da condição de finalização, representada pelo menor valor máximo admitido do erro absoluto médio no treinamento, que ainda não produz superajustamento; o qual é verificado pela redução do desempenho observado na amostra de validação. Essa etapa foi executada com uma rede de 20 neurônios na camada interna, sendo os valores testados para os máximos admitidos do erro absoluto médio, na escala reduzida das saídas (para o domínio de saída da função sigmoide, entre zero e um), com os valores da imprecisão sucessivamente decrescentes entre 0,1 e 0,01, com precisão de 0,005.

Ao final desta etapa, obteve-se a condição de finalização do treinamento, que foi o valor de 0,003 para o limite do erro absoluto médio, que completou o treinamento com 2.058 ciclos; resultando um modelo preliminar (Modelo_1) a ser utilizado como padrão de comparação para verificar se o modelo definitivo (Modelo_2) mantém desempenho semelhante, na validação, em relação ao modelo preliminar mais complexo (Modelo_1), conforme a proposta do método.

Esse modelo (Modelo_1), definido na etapa 1, mostrou “Muito Bom” desempenho (NS=0,900) durante o treinamento, apresentando relação próxima entre os valores de CSS observados e simulados (Figura 35a), com erros pequenos e bem distribuídos em torno do eixo zero (Figura 35b). A rede conseguiu representar muito bem o comportamento da CSS ao longo dos eventos analisados, assim como, os extremos da CSS estimada (Figura 35c). As demais estatísticas de desempenho calculadas, em g/L, foram: $EaM=0,06$; $Ea(50)=0,03$; $Ea(95)=0,21$; $Ea(Max)=0,32$ e $RMSE=0,091$. Dos 35 valores analisados na série de treinamento, 17 são superestimados e 18 subestimados pelo modelo.

Figura 35 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do Modelo_1, respectivamente, para as variáveis de entrada nível de água e turbidez



Fonte: Adaptado de Sari et al. (2017)

A rede apresentou capacidade de generalização muito boa para a série de verificação, atingindo NS de 0,924; ajustando muito bem os valores de CSS simulados aos observados (Figura 35a), com erros na saída da rede pequenos, homogêneos e bem distribuídos (Figura 35b). Além disso, representou muito bem o comportamento da CSS ao longo dos eventos analisados, com boa representação dos extremos de CSS (Figura 35d). As demais estatísticas

de desempenho calculadas, em g/L, foram: $EaM=0,04$; $Ea(50)=0,03$; $Ea(95)=0,16$; $Ea(Max)=0,28$ e $RMSE=0,07$. Dos 24 valores disponíveis para a verificação da rede, 17 foram superestimados e 7 subestimados pela RNA desenvolvida.

Apesar do ótimo desempenho apresentado pelo Modelo_1 durante o processo de treinamento e de verificação da RNA, é preciso avaliar se a arquitetura estabelecida para a rede é a mais adequada, já que o número de neurônios utilizados na camada intermediária foi mantido constante durante todo o treinamento da rede, tendo sido, propositadamente, adotado como um valor elevado (20 neurônios).

Na segunda etapa do método proposto, realizou-se o procedimento de procura da complexidade ideal da rede; ou seja, a definição do número mínimo de neurônios necessários na camada intermediária da RNA, que ainda não apresentava redução de desempenho, em relação ao modelo anterior (com 20 neurônios), propositalmente superdimensionado (Modelo_1). Após a aplicação do método proposto para a pesquisa da complexidade (etapa 2 da metodologia proposta), com uso da condição de finalização obtida na etapa anterior, resultou uma configuração com 3 neurônios na camada intermediária da RNA (Modelo_2), cujo treinamento foi completado com 4.010 ciclos.

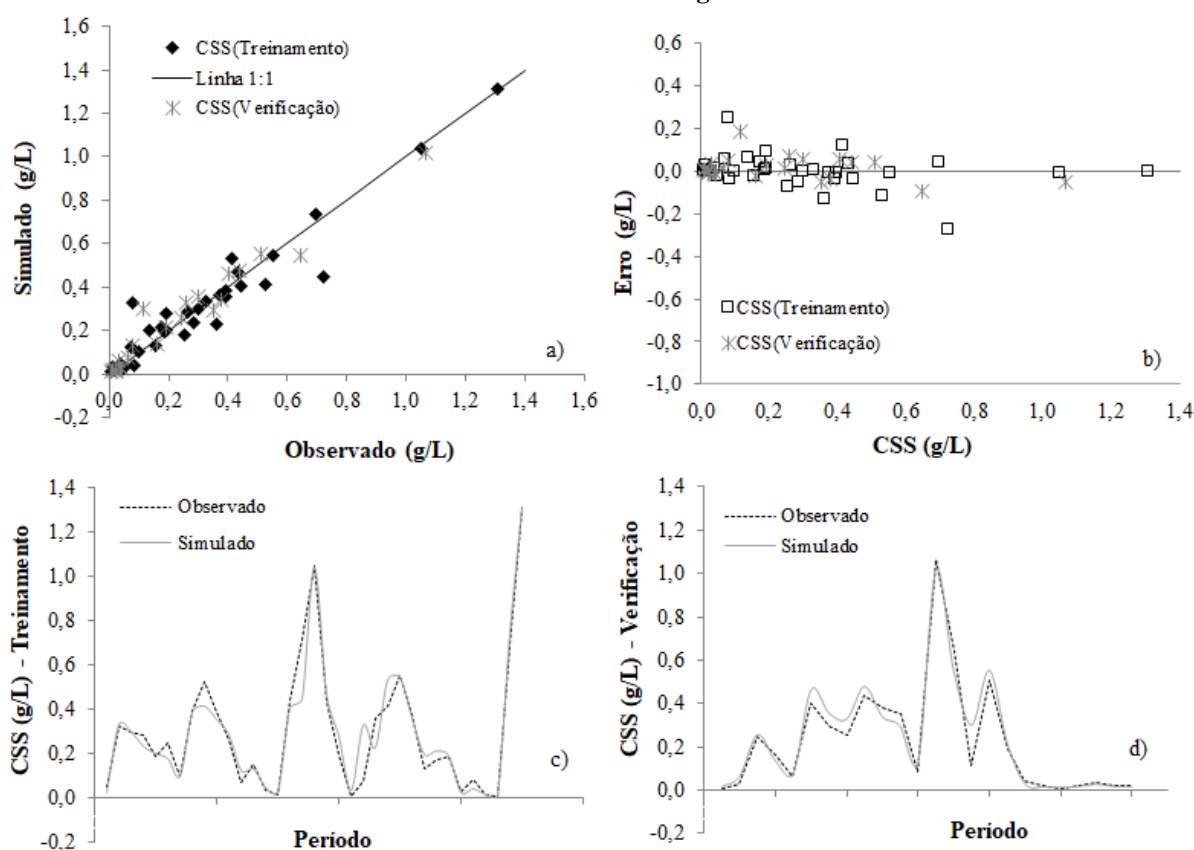
O NS resultante no treinamento dessa etapa foi igual a 0,926, obtendo-se ótimo ajuste entre os dados de CSS simulados e observados (Figura 36a), com a maioria dos valores de CSS simulados pela RNA próximos da situação de ajuste ideal (linha 1:1). Os erros resultantes na saída da rede foram pequenos e bem distribuídos, com valores próximos do eixo zero (Figura 36b), indicando baixa discrepância dos valores de CSS simulados, em relação aos valores reais, e boa representatividade da variação do comportamento da CSS ao longo dos eventos analisados, com boa representação dos extremos da CSS (Figura 36c). As outras estatísticas de desempenho calculadas, em g/L, foram: $EaM=0,05$; $Ea(50)=0,02$; $Ea(95)=0,22$; $Ea(Max)=0,27$ e $RMSE=0,079$. Dos 35 valores da série de treinamento, 20 foram superestimados e 15 subestimados pela RNA desenvolvida.

O NS obtido na verificação do Modelo_2 foi igual a 0,953, com as demais estatísticas de desempenho calculadas, em g/L, iguais a: $EaM=0,04$; $Ea(50)=0,03$; $Ea(95)=0,12$; $Ea(Max)=0,18$ e $RMSE=0,054$. Dos 24 valores disponíveis para verificação da rede treinada, 13 foram superestimados e 11 subestimados pelo modelo.

Os valores da série de verificação indicaram grande capacidade de generalização da rede, ajustando muito bem os dados de CSS simulados aos observados (Figura 36a), com poucas discrepâncias na distribuição dos erros (Figura 36b) e boa representatividade do comportamento

da CSS simulada, ao longo dos eventos, em relação aos valores reais monitorados; sendo os extremos de CSS, comumente, bem representados pelo modelo (Figura 36d).

Figura 36 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do Modelo_2, respectivamente, para as variáveis de entrada nível de água e turbidez



Fonte: Adaptado de Sari et al. (2017)

Tais resultados e estatísticas indicam que o Modelo_2, embora com complexidade menor (apenas 3 neurônios na camada interna), apresentou um desempenho até melhor, tanto no treinamento quanto na verificação, em comparação ao modelo intermediário (Modelo_1), que possuía 20 neurônios na camada interna. O Modelo_2 também apresentou boa capacidade de generalização para aplicações futuras, desde que observados os limites do domínio para o qual a rede foi treinada (turbidez entre 0 e 1800 NTU, nível de água entre 0 e 5 m e CSS entre 0 e 2 g/L).

Os resultados desse modelo são, ainda, visivelmente melhores do que aqueles advindos do emprego das funções explícitas baseadas na determinação da CSS em função do nível de água (NS na verificação igual a 0,58), e um pouco melhores do que os resultados obtidos para as funções explícitas ajustadas entre CSS e turbidez (NS=0,91) ou para a função explícita

ajustada para os dados de turbidez e nível de água, utilizados conjuntamente (na verificação: $NS=0,92$; $Ea(50)=0,04$; $Ea(95)=0,18$; $Ea(Max)=0,22$; $EaM=0,05$ e $RMSE=0,07$). Em geral, os extremos da CSS foram mais bem representados pela RNA, e o comportamento da CSS, ao longo do tempo, foi muito próximo do sedimentograma verificado na situação real, com menores erros em relação aos modelos definidos pelas funções explícitas.

Para o modelo alternativo, que tem a variável nível de água como única entrada da RNA, obteve-se, ao final da etapa 1, a condição de finalização do treinamento de 0,065 para o limite do erro absoluto médio, completando-se o treinamento com 85.635 ciclos. O modelo preliminar resultante nessa etapa (NívCSS_1) mostrou desempenho bem menor em relação ao modelo_1 testado para as duas entradas (nível de água e turbidez), tanto para o treinamento ($NS=0,389$) quanto para a verificação ($NS=0,533$) da rede.

As demais estatísticas calculadas, em g/L, foram: $EaM=0,13$ e $0,09$; $Ea(50)=0,06$ e $0,05$; $Ea(95)=0,59$ e $0,43$; $Ea(Max)=0,92$ e $0,74$ e $RMSE=0,226$ e $0,172$, para os processos de treinamento e de verificação da rede, respectivamente. Da série de treinamento (35 valores de CSS disponíveis), 21 dados de CSS foram superestimados e 14 foram subestimados pela rede; enquanto que, dos 24 valores da série de verificação, 17 foram superestimados e 7 subestimados pela rede.

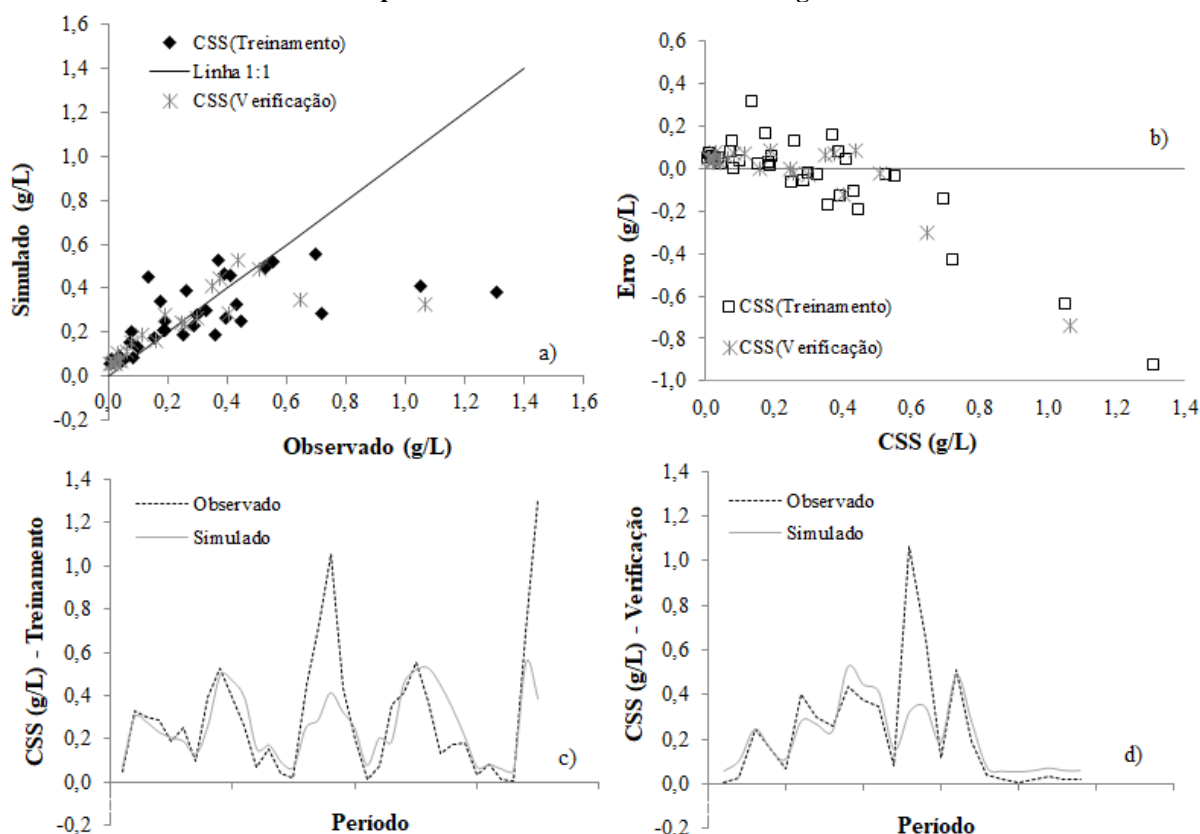
A relação entre os valores de CSS observados e simulados (Figura 37a) apresentou maiores diferenças para CSS superiores a 0,5 g/L, com erros mais elevados e mais distantes do eixo zero, tanto para o treinamento quanto para a verificação da rede (Figura 37b), em relação ao modelo de duas entradas. Para menores CSS, a RNA conseguiu representar um pouco melhor o comportamento da CSS ao longo dos eventos analisados (Figura 37c,d). Entretanto, os maiores erros observados para as CSS mais elevadas que, em geral, foram associadas aos maiores níveis de água (Figura 21a), constituem-se em um limitante para aplicações futuras desse modelo, já que a maior parte dos sedimentos é transportada durante os eventos de cheia.

Na segunda etapa do método proposto (modelo NívCSS_2), o erro escalonado médio limite observado no treinamento foi igual a 0,0603, sendo necessários 84.604 ciclos para completar o processo de treinamento, atingindo-se NS igual a 0,548. O número de neurônios definido nessa fase foi igual a 3, bem menor do que os 20 neurônios assumidos como padrão na arquitetura da rede do modelo, definida na primeira etapa.

As demais estatísticas apresentaram uma pequena melhora em relação à etapa anterior, alcançando valores, em g/L, de: $EaM=0,12$; $Ea(50)=0,06$; $Ea(95)=0,44$; $Ea(Max)=0,66$ e $RMSE=0,195$. Já na fase de verificação do modelo, o NS observado foi igual a 0,70, com

EaM=0,07; Ea(50)=0,02; Ea(95)=0,34; Ea(Max)=0,57 e RMSE=0,138 em g/L. Nesse caso, dos 35 valores da série de treinamento, 20 foram superestimados e 15 foram subestimados pelo modelo. Já na série de verificação, dos 24 valores de CSS analisados, 13 foram superestimados e 11 foram subestimados pela rede treinada.

Figura 37 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo NívCSS_1, respectivamente, para a variável de entrada nível de água



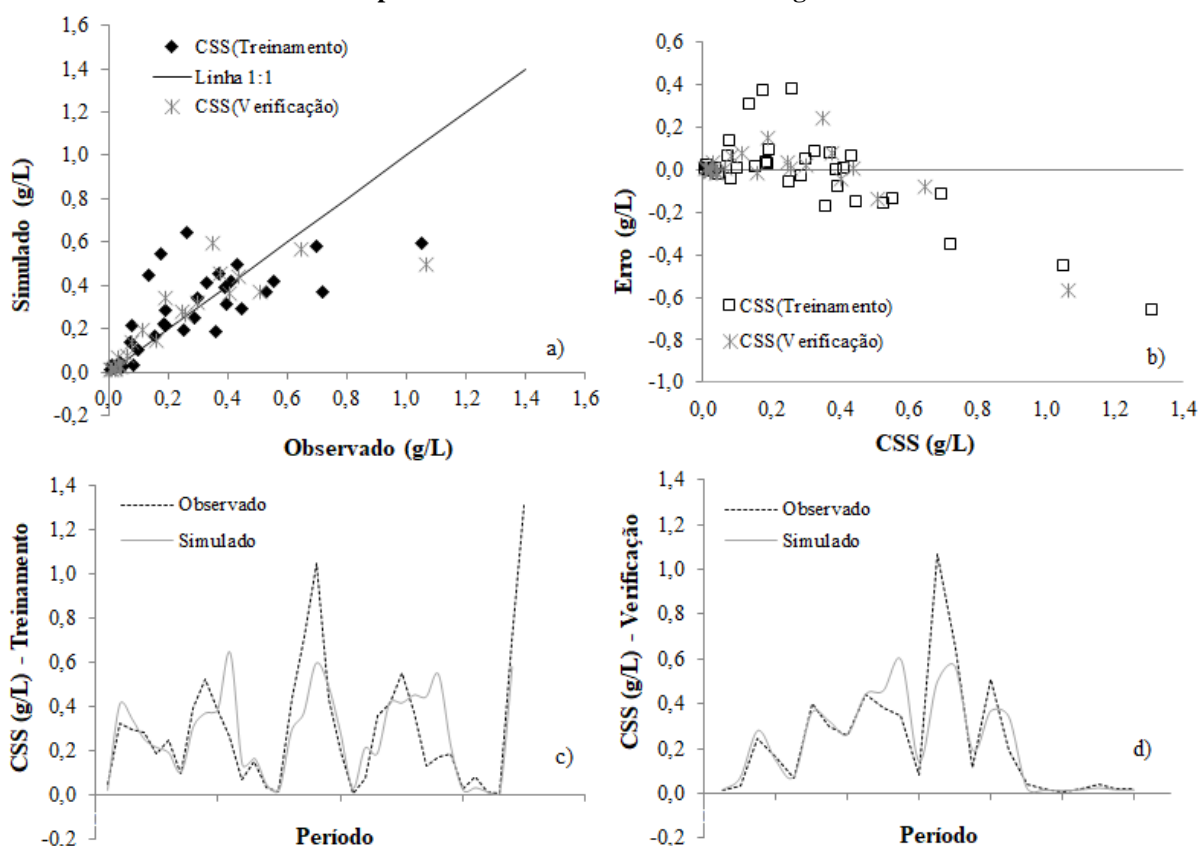
Fonte: autora

Contudo, da mesma forma que ocorrido anteriormente, o modelo final resultante dessa etapa (NívCSS_2) apresentou erros elevados na representação dos picos para CSS superiores a 0,5 g/L (Figura 38b), com pior ajuste entre dados calculados e monitorados (Figura 38a) em comparação ao modelo de duas entradas; embora esse ajuste tenha sido um pouco melhor do que aquele definido na etapa 1 da metodologia proposta.

A exemplo do que ocorreu no modelo NívCSS_1, os erros mais significativos foram associados, frequentemente, às maiores CSS, transportadas em sua maioria nos grandes eventos. Dessa forma, a aplicação desse modelo somente é indicada para as situações extremas, em que não existirem dados disponíveis de turbidez para uso do modelo RNA, baseado nas duas entradas (nível de água e turbidez).

Ainda assim, o desempenho desse modelo RNA, que tem por base informações apenas de nível de água (NívCSS_2), mostrou-se superior aquele observado para a função explícita desenvolvida para essa mesma entrada (na verificação: NS=0,581; EaM=0,10; Ea(50)=0,05; Ea(95)=0,35; Ea(Max)=0,66 e RMSE=0,16), representando um pouco melhor o comportamento real do transporte de sedimentos (Figura 38c,d). Tais funções são tradicionalmente empregadas para o desenvolvimento de modelagens hidrossedimentológicas.

Figura 38 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo NívCSS_2, respectivamente, para a variável de entrada nível de água



Fonte: autora

O modelo alternativo que tem a turbidez como única variável de entrada da RNA resultou, ao final do treinamento da etapa 1, em erro escalonado médio limite de 0,04, sendo necessária a execução de 9.405 ciclos para conclusão do processo de aprendizado da rede.

O NS resultante dessa primeira fase (modelo TurbCSS_1) foi igual a 0,879, e as demais estatísticas, em g/L, foram: EaM=0,07; Ea(50)=0,04; Ea(95)=0,27; Ea(Max)=0,29 e RMSE=0,101. No processo de verificação, a rede manteve o desempenho (“Muito Bom”), com pequena melhoria (NS=0,911), sendo as outras estatísticas, em g/L, iguais a: EaM=0,06;

$Ea(50)=0,04$; $Ea(95)=0,18$; $Ea(Max)=0,24$ e $RMSE=0,075$. Dos 35 valores da série de treinamento, 20 foram superestimados e 15 subestimados pela RNA. Por outro lado, na verificação da rede treinada, 17 dos 24 valores de CSS foram superestimados e 7 foram subestimados pela rede.

Na etapa de procura da complexidade ideal da rede (etapa 2), o modelo resultante (TurbCSS_ 2) derivou em 2 neurônios necessários para a camada interna, com $NS=0,893$ no treinamento e $NS=0,899$ na etapa de verificação da rede.

As demais estatísticas de desempenho, em g/L, foram iguais a: $EaM=0,06$; $Ea(50)=0,03$; $Ea(95)=0,27$; $Ea(Max)=0,31$ e $RMSE=0,094$ no treinamento e $EaM=0,05$; $Ea(50)=0,03$; $Ea(95)=0,22$; $Ea(Max)=0,26$ e $RMSE=0,080$ na verificação da rede. Alguns dos picos são subestimados e outros superestimados pelo modelo, o mesmo ocorrendo para os menores valores de CSS. Dos 35 valores da série de treinamento, 17 dos dados de CSS foram superestimados e 18 foram subestimados; enquanto que, dos 24 valores de CSS disponíveis para o processo de verificação, 19 foram superestimados e 5 subestimados pela RNA desenvolvida.

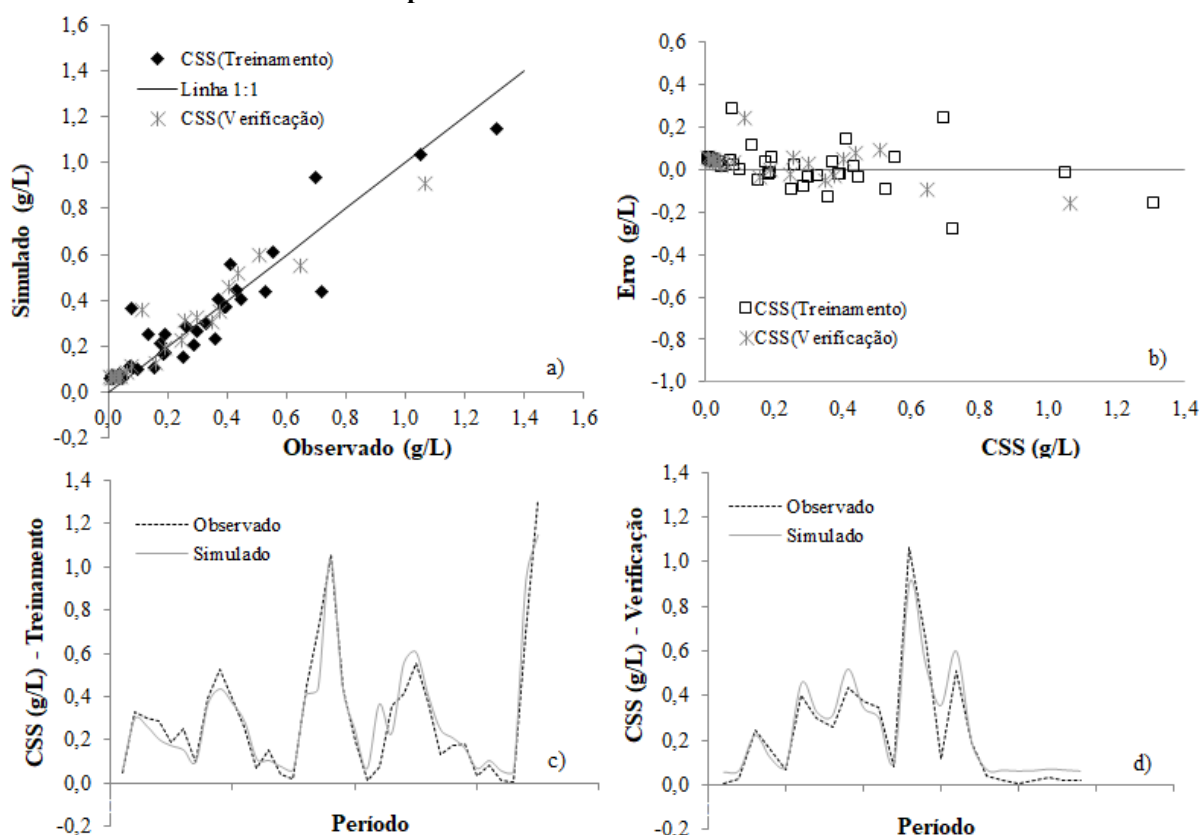
Esses índices de desempenho observados foram muito próximos daqueles determinados para a função de ajuste entre turbidez e CSS, que também apresentou “Muito Bom” desempenho durante o processo de verificação ($NS=0,911$; $EaM=0,06$; $Ea(50)=0,04$; $Ea(95)=0,18$; $Ea(Max)=0,23$ e $RMSE=0,08$).

Os valores de CSS observados e simulados (Figura 39a, Figura 40a) apresentaram melhor ajuste, em comparação ao modelo que utiliza apenas dados de nível de água como entrada da rede (Figura 37 e Figura 38). Em contrapartida, os resultados de desempenho observados foram inferiores àqueles verificados para o modelo de duas entradas (nível de água e turbidez), que conseguiu representar melhor o fenômeno do transporte de sedimentos nessa bacia. Os erros na determinação da CSS também foram inferiores e melhor distribuídos, em relação ao modelo que tem por base apenas informações de nível de água (Figura 39b, Figura 40b), resultando em melhor representatividade da variação do comportamento da CSS ao longo do tempo, tanto para os dados empregados no treinamento quanto para a verificação da rede. Houve ainda, melhor representação dos extremos da CSS (Figura 39c,d e Figura 40c,d).

O pior desempenho verificado, tanto para o modelo RNA quanto para as funções explícitas que tem por base somente informações de nível de água, ocorreu em razão da complexa relação não linear existente entre vazão e sedimentos suspensos, bem como, pelo fenômeno de histerese relacionado ao transporte das partículas de sedimento e ao regime de

vazões atuantes. Esses resultados também mostraram que os modelos de RNAs conseguiram capturar melhor as variações da CSS ao longo dos eventos, para os diferentes regimes hidrológicos e épocas do ano analisados, provavelmente, em função da grande capacidade de adaptação e de organização das informações em modelos não-lineares, característica de modelos de RNA.

Figura 39 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo TurbCSS_1, respectivamente, para a variável de entrada turbidez

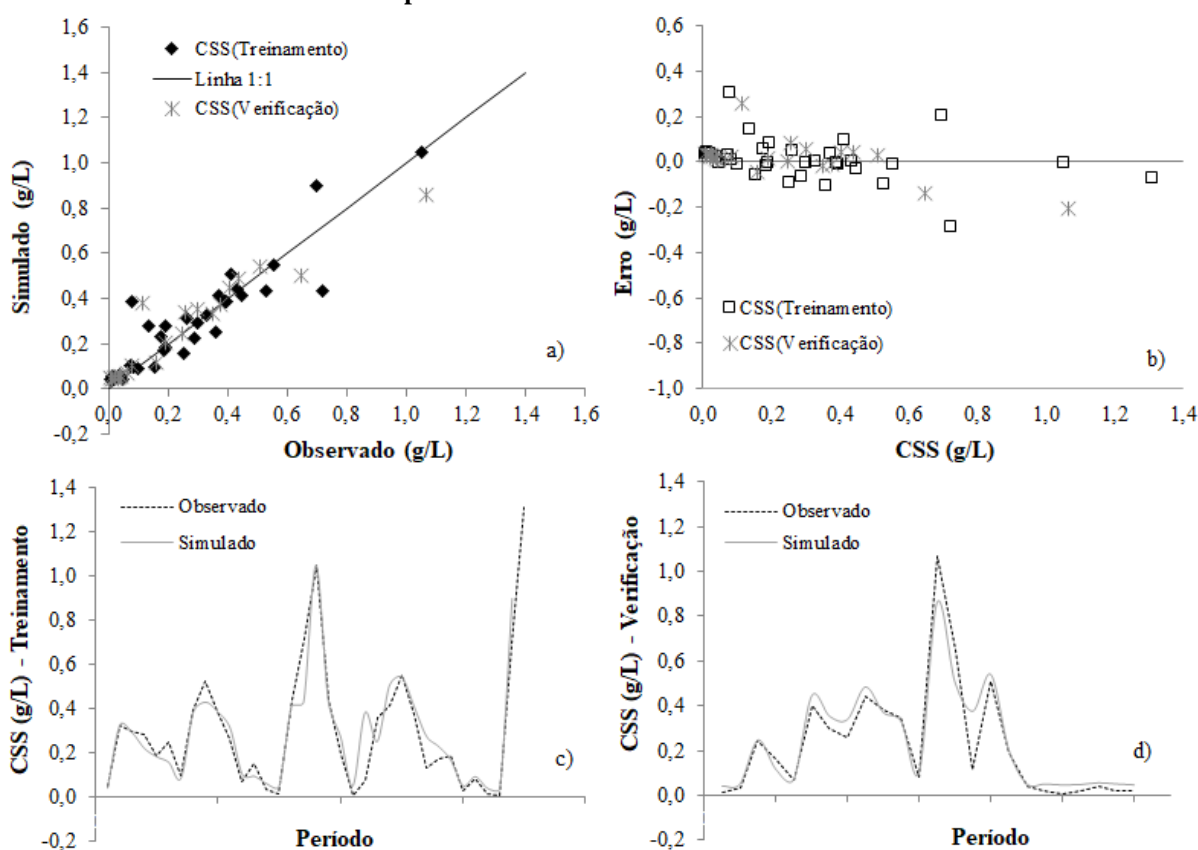


Fonte: autora

Wang, Traore e Kerh (2008) avaliaram a potencialidade das RNAs para prever dados horários de CSS no reservatório de Jiasian, em Taiwan. Os autores utilizaram uma RNA *feedforward* de três camadas, com algoritmo retropropagativo (método do Gradiente de Descida) para treinamento da rede, empregando como entrada dados de turbidez e vazão, em conjunto e isoladamente. A exemplo do que ocorreu nesse estudo, os melhores resultados reportados pelos autores foram observados para o modelo que emprega ambas as informações como entrada da RNA. No processo de treinamento, o coeficiente de Pearson (R^2) obtido foi igual a 0,977; 0,929 e 0,883 para os cenários que utilizaram, respectivamente, dados de turbidez e vazão conjuntamente (cenário 1), turbidez isoladamente (cenário 2) e; dados de vazão unicamente

(cenário 3). No processo de verificação, o melhor desempenho também foi observado para o modelo de duas entradas ($R^2=0,930$), seguido do modelo que empregou somente informações de turbidez ($R^2=0,915$). Analogamente ao que foi verificado nessa pesquisa para a entrada única de nível de água para a RNA, o resultado menos expressivo, conforme os autores, também foi observado para o cenário que empregou apenas dados de vazão como entrada da RNA ($R^2=0,524$).

Figura 40 - CSS observada e calculada em relação à reta de ajuste ideal (a), erro verificado entre os valores calculados e observados da CSS (b), e comportamento dos valores de CSS calculados e observados (c, d); considerando os processos de treinamento e verificação do modelo TurbCSS_2, respectivamente, para a variável de entrada turbidez



Fonte: autora

Resultados descritos por outros autores (ver APÊNDICE A), em diferentes regiões, também demonstram uma melhoria do desempenho dos modelos de RNAs, quando empregadas informações conjuntas de mais de uma variável de influência sobre os processos de transporte de sedimentos, ou ainda, quando utilizados diferentes intervalos de tempo para uma mesma variável (JAIN, 2001; CIGIZOGLU, 2004; KISI, 2005; SARANGI et al., 2005; CIGIZOGLU e ALP, 2006; RAGHUWANSHI, SINGH e REDDY, 2006; ZHU et al., 2007; NOURANI,

2009; ULKE, TAYFUR e OZKUL, 2009; WANG, KERH e TRAORE, 2009; MELESSE et al., 2011; KISI e SHIRI, 2012).

Os estudos descritos no APÊNDICE A evidenciaram ainda que, a exemplo do que ocorreu nessa pesquisa, os modelos baseados em RNAs, geralmente, têm resultado em melhor desempenho na estimativa dos processos hidrossedimentológicos, em comparação aos tradicionais ajustes comumente empregados (JAIN, 2001; CIGIZOGLU, 2004; KISI, 2004, 2005; SARANGI et al., 2005; AGARWAL et al., 2006; RAGHUWANSHI, SINGH e REDDY, 2006; ARDIİÇHOGLU et al., 2007; ALP e CIGIZOGLU, 2007; ZHU et al., 2007; HAMIDI e KAYAALP, 2008; COBANER, UNAL e KISI, 2009; NOURANI, 2009; RAJAEI et al., 2009; ULKE, TAYFUR e OZKUL, 2009; WANG, KERH e TRAORE, 2009; NOURANI e KALANTARI, 2010; MELESSE et al., 2011; RAJAEI et al., 2011; BAYRAM, KANKAL e ÖNSOY, 2012; MUHAMMADI, AKBARI e AZIZZIAN, 2012; NOURANI, KALANTARI e BAGHANAM, 2012; SHABANI e SHABANI, 2012; BOUKHRISSE et al., 2013; EISAZADEH et al., 2013; GHORBANI et al., 2013). Isso demonstra que as RNAs podem ser uma boa alternativa para a estimativa da CSS em bacias hidrográficas brasileiras, tendo por base medições indiretas de outras variáveis, tais como: nível de água, vazão e turbidez.

No período analisado nessa pesquisa (2013 a 2015), em que os dados de turbidez estavam disponíveis (ou foram preenchidos) para posterior utilização na modelagem da produção de sedimentos, a RNA mais utilizada para estimativa da CSS foi o Modelo_2, que empregou como entrada os dados de turbidez e de nível de água na bacia do Taboão.

Para a situação descrita no item 4.4, em que existiam 502 registros falhos nos dados de turbidez e de nível de água simultaneamente (30/11/2015 e 04/12/2015), optou-se por empregar, na estimativa da CSS, o modelo que utilizava somente dados de turbidez (TurbCSS_2) como entrada da rede. Essa escolha foi realizada para evitar que a variável nível de água fosse utilizada duas vezes, sequencialmente, uma para determinação da turbidez (RNA com entrada nível de água) e outra para cálculo da CSS (RNA com entrada turbidez e nível de água).

4.8 Estatísticas gerais dos dados diários observados na bacia do Taboão: precipitação, temperatura do ar máxima e mínima, radiação solar, umidade relativa do ar, velocidade do vento, nível de água, vazão, turbidez, CSS e; produção de sedimentos diária, mensal e anual

Na Tabela 34 são apresentados, para a bacia do Taboão, os valores diários médios, medianos, máximos e mínimos para cada ano utilizado nas simulações realizadas com o modelo SWAT e SWAT-CUP, com descrição das variáveis precipitação, temperatura do ar máxima e

mínima, radiação solar, umidade relativa do ar, velocidade do vento, nível de água, vazão, turbidez e CSS.

Tabela 34 - Resumo das estatísticas diárias das variáveis precipitação, temperatura do ar máxima e mínima, radiação solar, umidade relativa do ar, velocidade do vento, nível de água, vazão, turbidez e CSS para bacia do Taboão; considerando os anos utilizados para a calibração e a verificação do modelo SWAT

Variável	Estatística	2011	2013	2014	2015	2016
Precipitação (mm)*	média diária	4,48	3,26	4,93	4,72	3,64
	mediana diária	0,15	0,10	0,20	0,37	0,25
	máxima diária	87,80	46,50	105,55	72,34	61,70
	mínima diária	0,00	0,00	0,00	0,00	0,00
	total anual	1634,14	1188,71	1801,12	1724,24	1332,27
Temperatura máxima (°C)	média diária	24,90	24,62	25,49	25,25	22,58
	mediana diária	26,00	25,40	25,50	26,00	22,40
	máxima diária	37,00	38,00	37,50	34,00	35,00
	mínima diária	9,10	7,10	10,50	11,50	8,90
Temperatura mínima (°C)	média diária	13,87	13,35	15,05	15,38	15,38
	mediana diária	14,60	14,00	15,80	16,00	16,61
	máxima diária	22,50	24,20	24,20	24,20	26,53
	mínima diária	-1,00	-1,40	0,00	1,80	-1,60
Radiação solar (MJ/m ² /dia)	média diária	15,85	17,80	17,35	16,24	16,87
	mediana diária	14,87	18,00	16,40	15,08	15,75
	máxima diária	31,03	31,14	31,05	30,98	33,33
	mínima diária	4,81	2,88	4,81	4,81	0,55
Umidade relativa do ar (%)	média diária	75,28	74,79	76,45	78,56	75,77
	mediana diária	75,50	75,50	77,00	79,30	77,10
	máxima diária	98,50	95,50	96,52	96,10	96,63
	mínima diária	34,30	38,60	36,00	45,50	44,75
Velocidade do vento (m/s)	média diária	2,80	1,98	1,47	1,32	1,08
	mediana diária	2,50	1,80	0,90	0,80	0,66
	máxima diária	7,90	6,90	7,70	6,90	6,70
	mínima diária	0,00	0,00	0,00	0,00	0,00
Nível de água (cm)	médio diário	68,63	65,89	84,67	81,44	70,93
	mediano diário	64,23	64,20	82,31	75,17	69,21
	máximo diário	95,05	84,66	122,10	124,52	100,37
	mínimo diário	40,89	58,19	56,43	56,54	52,47
Vazão (m ³ /s)	média diária	2,46	2,27	3,61	3,38	2,63
	mediana diária	2,15	2,15	3,44	2,93	2,50
	máxima diária	4,35	3,61	6,30	6,48	4,73
	mínima diária	0,92	1,72	1,59	1,60	1,31
Turbidez (NTU)	média diária	-	60,38	75,90	109,98	-
	mediana diária	-	29,03	35,57	44,61	-
	máxima diária	-	1202,00	805,39	1077	-
	mínima diária	-	7,85	2,40	6,15	-
CSS (g/L)	média diária	-	0,040	0,065	0,0792	-
	mediana diária	-	0,025	0,037	0,0334	-
	máxima diária	-	1,429	0,800	1,1250	-
	mínima diária	-	0,016	0,015	0,0163	-

* Estatísticas determinadas a partir dos valores médios diários dos quatro PVGs (34, 40, 43 e 51) empregados na pesquisa
- indica dados não disponíveis no ano

Fonte: autora

As estatísticas das precipitações diárias e também o total anual são mais elevados para o ano de 2014, seguido dos anos de 2015 e 2011, sendo menores para 2013 e 2016, anos caracterizados como mais secos. De modo geral, os níveis de água e as vazões seguem tendência semelhante, com maiores valores registrados em 2014 e 2015 e menores em 2013.

A turbidez e a CSS também mostram variações semelhantes às vazões, com valores médios e medianos mais elevados nos anos de 2015 e 2014, e menores valores em 2013, embora

os máximos diários nesse último ano tenham alcançado valores superiores ao demais anos; isso, provavelmente, em função da menor diluição da turbidez em decorrência das menores vazões ocorridas nesse ano de 2013.

As variáveis temperatura do ar, radiação solar e umidade relativa do ar apresentam estatísticas próximas para os diferentes anos analisados nessa pesquisa, não sendo possível definir um ano, em específico, que apresente os valores mais elevados para todas as estatísticas descritas (média, mediana, máximo ou mínimo); enquanto que a velocidade do vento é, frequentemente, maior no ano de 2011.

Na Tabela 35 são apresentadas as produções de sedimento médias, medianas, mínimas e máximas, em um intervalo de tempo diário e mensal, para a bacia do Taboão.

Tabela 35 - Resumo das estatísticas da produção de sedimentos diária e mensal na bacia do Taboão

Estatística	Produção diária (ton/ha/dia)			Produção mensal (ton/ha/mês)		
	2013	2014	2015	2013	2014	2015
Média	0,00180	0,00525	0,00675	0,05486	0,15980	0,20529
Desvio	0,00874	0,01392	0,02096	0,05895	0,13544	0,16443
Mediana	0,00056	0,00132	0,00104	0,02442	0,12220	0,15069
Minima	0,00021	0,00017	0,00021	0,01262	0,01504	0,03526
Maxima	0,14087	0,09738	0,24426	0,17656	0,46540	0,54007

Fonte: autora

Já na Tabela 36 são descritos os resultados da produção de sedimento anual e da precipitação média anual de todos os PVGs utilizados na pesquisa, a porcentagem de lacunas nos dados de precipitação do PVG 40 utilizado para cálculo da erosividade, e a erosividade da chuva para esse pluviógrafo; estimada com separação dos eventos utilizando quatro critérios diferentes, para os anos de 2013 a 2015.

Tabela 36 - Produção de sedimentos na bacia do Taboão, total pluviométrico anual e erosividade da chuva para o PVG 40, considerando os anos de 2013 a 2015

Ano	Precipitação média anual (mm)	% lacuna PVG 40	Erosividade 0-10-5 PVG 40 MJ/ha/mm	Erosividade 0-10-0 PVG 40 MJ/ha/mm	Erosividade 5-10-20 PVG 40 MJ/ha/mm	Erosividade 10-10-10 PVG 40 MJ/ha/mm	Produção sedimento (t/ha/ano)
2013	936	14	200	2008	884	967	0,66
2014	1525	0,63	3783	3712	1742	1279	1,92
2015	1137	1,04	4527	4542	2674	2564	2,46

Critério de separação dos eventos para erosividade => Erosividade 5-10-20: o nº "5" indica a intensidade mínima considerada para a chuva (mm/h); o nº "10" indica o intervalo de tempo dos registros pluviométricos utilizados (min); o nº "20" indica o total mínimo considerado para cada chuva (mm)

Fonte: autora

A produção de sedimentos estimada na seção do exutório da bacia do Taboão foi de 0,66, 1,92 e 2,46 t/ha/ano para os anos de 2013, 2014 e 2015, respectivamente. Os maiores valores e as médias mais elevadas de produção de sedimento, em uma escala de tempo diária e mensal, foram observados para o ano de 2015 e 2014; o que é condizente com os maiores volumes de chuva registrados para esses anos. O ano de 2013, por outro lado, com menores totais acumulados de chuva, foi o ano que, comumente, apresentou as menores produções de sedimento por hectare.

A precipitação média anual determinada, considerando todos os postos pluviométricos disponíveis e preenchidas todas as falhas existentes, foi igual a 936, 1525 e 1137 mm para os anos de 2013, 2014 e 2015, respectivamente.

O ano de 2014 resultou em menor produção de sedimentos em comparação ao ano de 2015, apesar de ter tido maior precipitação total anual. Isso ocorreu porque a produção de sedimentos é dependente não somente da quantidade de solo erodido das áreas da bacia, como também dos sedimentos provenientes da estrada, das margens e do próprio leito do rio. Além disso, na bacia do Taboão, também existe a contribuição de sedimentos provenientes de voçorocas, o que pode ter influenciado a ocorrência de valores mais elevados de produção de sedimentos nos anos de chuva mais intensa e de maior potencial erosivo.

De fato, Viero (2004) mapeou 83 voçorocas na bacia do Taboão, sendo que destas, 54% se encontravam ativas no ano do estudo. Ainda segundo a autora, das voçorocas analisadas na pesquisa, 18% delas possuíam ligações aos canais de drenagem, ou seja, estavam diretamente ligadas a pontos de transporte de sedimentos aos rios, 78% delas estavam situadas em talwegues, mas desconectadas da rede de drenagem, e somente 4% das voçorocas não apresentaram qualquer relação com a rede de drenagem.

Maier (2013) pesquisou as fontes dos sedimentos em suspensão coletados no exutório, para uma pequena bacia agrícola embutida na bacia analisada nessa pesquisa (sub-bacia do Donato), concluindo que, dos sete eventos monitorados, seis tiveram a maior parte dos sedimentos provenientes das áreas de lavoura; sendo essa a fonte mais importante de aporte de sedimentos na região, seguida das margens dos rios e, por último, das estradas.

Portanto, a maior parcela dos sedimentos produzidos na bacia em questão é proveniente das áreas de lavoura, que são extremamente afetadas pela chuva. Essa influência não depende somente da lâmina de água total precipitada sobre o solo, mas também, da intensidade das chuvas e de seu potencial de erosividade.

Essa conclusão é confirmada pela análise da erosividade das chuvas para os anos de 2013, 2014 e 2015, uma vez que, independente do critério utilizado para a separação dos eventos de chuva, o ano de 2015 sempre foi enquadrado como de maior erosividade se comparado aos anos de 2014 e 2013; possuindo potencial 1,2 a 2,01 vezes maior que os outros anos, conforme critério de separação considerado. Esse fato pode explicar a maior produção de sedimentos obtida para o ano de 2015, apesar de seu menor total pluviométrico anual em relação ao ano de 2014.

Estudo realizado por Souza et al (2006) na bacia do Potiribu, na qual a bacia do Taboão está inserida, mostra uma produção de sedimentos de 0,18 ton/ha/ano quando utilizado o Protocolo ANA (CARVALHO et al., 2000) e/ou a curva de permanência (CARALHO, 2008) para cálculo da produção diária de sedimentos. Por outro lado, quando empregada a equação da USLE, associada à taxa de entrega de sedimentos (SDR) em relação a declividade da bacia (equação de Willians e Berndt, 1972) esse valor eleva-se para 0,22 ton/ha/ano, alcançando 0,74 ton/ha/ano quando utilizada a USLE associada a SDR em relação à área da bacia (equação de Vanoni, 1975), para determinar a produção de sedimentos que chega ao rio. Os valores mais elevados da produção de sedimentos são justificados, já que a bacia do Potiribu possui uma área de 610,10 km² e uso do solo caracterizado por intensa atividade agrícola, incluindo o cultivo de soja, trigo e aveia; sendo o solo composto predominantemente por Latossolo e Terra Roxa. Há que destacar, entretanto, que os valores reportados pelos autores não foram verificados na prática e, portanto, não é possível afirmar qual dos métodos empregados é o mais preciso, ainda mais quando se considera que os dados utilizados no estudo para o método do Protocolo ANA e para a Curva de permanência são resultantes do monitoramento realizado pela ANA e, dessa forma, podem não ser completamente representativos da área em questão, já que a maioria das coletas são realizadas em níveis normais do rio.

Baltokoski (2008) reportou uma produção média anual de 293,57 kg/ha/ano (ou 0,294 ton/ha/ano), para duas microbacias hidrográficas contíguas, dos rios Conrado e Pinheiro, afluentes do Rio Pato Branco (municípios de Pato Branco e Mariópolis, Paraná). O monitoramento da vazão e dos sedimentos foi realizado nos anos de 2004 e 2005. Bonumá et al. (2010) descreveram uma produção de sedimentos média de 14,03 ton/ha, medida no exutório da bacia do Arroio Lino (Agudo/RS), no período de janeiro a dezembro de 2005.

Moro (2005), na microbacia hidrográfica do Ribeirão do Marins, localizada em Piracicaba (SP), observou valores mensais variando de 0,0001 a 0,8859 ton/ha/mês para o ano de 1999 e entre 0,0006 e 0,2596 ton/ha/mês no ano 2000; totalizando 1,619 ton/ha/ano em 1999

e 0,838 ton/ha/ano em 2000, valores próximos aos observados nesse estudo para os anos de 2014 e 2013, respectivamente.

4.9 Modelagem da hidrologia e da produção de sedimentos na bacia do Taboão utilizando o modelo SWAT e chuva horária, com emprego do método de Green & Ampt

A execução do modelo SWAT sem a realização do processo de calibração, utilizando os valores padrão dos parâmetros (*default*) do modelo e também os parâmetros previamente calibrados por Depiné (2014) para a vazão diária (apresentados na Tabela 18), mostrou falhas na capacidade de descrever os processos hidrossedimentológicos observados na bacia em questão, com escoamento superficial baixo, pequena infiltração da água no solo e elevado escoamento lateral (subsuperficial).

Para a simulação da vazão mensal, no período de 2013 a 2016, o modelo resultou em desempenho menor do que para a estimativa das vazões diárias. O NS e o PBIAS foram iguais a 0,33 e 23,13% para as vazões médias e 0,33 e -15,10% para as vazões mínimas mensais, respectivamente. Já para a simulação das vazões máximas mensais, o desempenho do modelo foi ainda pior, atingindo NS de -1,27 e PBIAS de 69,75%. Tais estatísticas evidenciaram a inadequabilidade do modelo em prever as vazões mensais, especialmente os valores máximos, mesmo utilizando-se os parâmetros da calibração prévia efetuada por Depiné (2014) para uma escala diária.

Considerando os dados médios diários de vazão no exutório da bacia do Taboão, no período de 2013 a 2016, o NS obtido foi igual a 0,41, elevando-se para 0,44 quando analisados os valores mínimos diários da vazão monitorada e; decrescendo (NS=0,17) para as vazões máximas diárias. O PBIAS observado foi igual a 24,92% para as vazões médias diárias, 38,05% para as vazões máximas e 13,08% para as vazões mínimas diárias. Os melhores resultados para a simulação dos processos diários, em comparação ao passo de tempo mensal, são justificados pelo fato de Depiné (2014) ter executado a calibração dos parâmetros do modelo para uma escala de saída diária.

Observou-se, portanto, a insatisfatoriedade do modelo em representar adequadamente os valores (diários e mensais) da vazão pelo critério do NS, com resultados piores para as vazões máximas; indicando que o modelo tende a subestimar a vazão observada. Tais valores, conforme critérios propostos por Moriasi et al. (2007), classificaram o desempenho do modelo como “Insatisfatório” ($NS \leq 0,5$), apontando a necessidade de realização de um adequado processo de calibração do modelo SWAT. Isso muito embora, em termos de estatística PBIAS

($PBIAS < \pm 25\%$), o modelo pudesse ser considerado adequado para a previsão da vazão média e mínima, em ambas as escalas de tempo.

Para a simulação da produção de sedimentos, utilizando os parâmetros da calibração realizada por Depiné (2014), o desempenho do modelo mostrou-se “Insatisfatório”, com NS igual a -1,01 e PBIAS de 99,13% para uma escala mensal e NS igual a -0,05, com PBIAS de 99,14%, para as saídas em um passo de tempo diário; considerando os anos de 2013 a 2015.

Dessa forma, procedeu-se a calibração do modelo, associada a um processo de análise de sensibilidade, tomando-se como base a calibração manual já realizada por Depiné (2014). Os valores iniciais dos parâmetros adotados para a calibração automática do modelo, realizada com emprego do SWAT-CUP, foram considerados iguais aos valores finais reportados em Depiné (2014), conforme descrições e tabelas já apresentadas na metodologia. Após a efetivação da calibração automática realizou-se a etapa de verificação dos valores calibrados.

A análise de sensibilidade foi verificada para 27 parâmetros do modelo SWAT, relacionados aos processos hidrológicos, e para 21 parâmetros do modelo, referentes à produção de sedimentos, considerando-se a execução de 500 simulações em cada interação realizada. Os efeitos da variação dos parâmetros foram classificados (*p-Value* e *t-Stat*), sendo que o maior efeito (maior sensibilidade) foi colocado na primeira posição no *rank*.

Foram considerados dois tipos de ranqueamentos, dependendo da função objetivo utilizada: i) Coeficiente de Nash-Sutcliffe entre a vazão observada e simulada pelo modelo SWAT e; ii) Coeficiente de Nash-Sutcliffe entre a produção de sedimentos observada e simulada pelo modelo SWAT. Cada uma dessas análises é apresentada nos itens 4.9.1 e 4.9.2, na descrição dos resultados do modelo para simulação dos processos hidrológicos e sedimentológicos, respectivamente.

4.9.1 Análise de sensibilidade, calibração e verificação dos processos hidrológicos na bacia do Taboão


Para a simulação dos processos hidrológicos no modelo SWAT considerou-se os anos de 2013, 2014 e 2016 para a calibração do modelo, e os anos de 2011 e 2015 para a realização da etapa de verificação. Durante o processo de calibração, a estabilização das condições iniciais foi considerada satisfeita pela simulação dos anos de 2008 e 2009 como tempo de aquecimento.

A análise de sensibilidade para a calibração diária e mensal foi realizada considerando-se 27 parâmetros do modelo SWAT, escolhidos entre os citados nas análises de sensibilidade

para a simulação da hidrologia no Brasil e em outros locais de estudo, conforme descrito na Tabela 5, e sugerido por Arnold et al. (2012b).

Os 27 parâmetros analisados apresentaram variações maiores ou menores para as estatísticas *p-Value* e *t-Stat* (Figura 41, Tabela 37), sendo classificados quanto à importância dessa variação, conforme categorias propostas por Van Griensven et al. (2006), descritas na Tabela 4. Essa classificação de importância considerou a posição do parâmetro no ranking de sensibilidade, para categorizá-lo como “muito importante” (posição 1), “importante” (posições 2 a 6), “ligeiramente importante” (posições 7 a 19) e; “sem importância” (acima da posição 20).

Figura 41 - Resultados da análise de sensibilidade para a calibração dos parâmetros para a simulação da vazão diária na bacia do Taboão, utilizando o Método de Green & Ampt



Considerando os resultados para a estatística *p-Value* e *t-Stat*, a ordem de sensibilidade e a importância no processo de calibração dos 27 parâmetros testados são apresentadas na Tabela 38. De acordo com essa classificação, percebe-se que o parâmetro LAT_TTIME (tempo do escoamento lateral) foi o mais sensível na análise realizada para a calibração diária e o CANMX (armazenamento de água máximo na copa das árvores) foi o parâmetro mais importante na calibração mensal. Tais parâmetros foram, portanto, fundamentais no processo de calibração da hidrologia na bacia do Taboão.

Tabela 37 - Resultados da análise de sensibilidade para calibração dos parâmetros para a simulação da vazão mensal na bacia do Taboão, utilizando o Método de Green & Ampt

Vazão Mensal		
Nome do parâmetro	t-Stat	p-Value
CANMX	22,65	1,97E-77
LAT_TTIME	-19,94	1,23E-64
RCHRG_DP	-10,05	1,13E-21
GWQMN	-8,54	1,80E-16
SHALLST	6,05	3,01E-09
HRU_SLP	3,71	0,00023
SOL_K	2,47	0,01378
SOL_AWCI	2,43	0,01553
CN2	2,18	0,02970
ALPHA_BF	2,00	0,04601
SLSOIL	-1,81	0,07078
OV_N	-1,38	0,16816
BLAI	1,37	0,17165
REVAPMN	1,08	0,28053
BIOMIX	-1,04	0,29833
CH_K1	-0,92	0,35951
EPCO	-0,73	0,46429
CH_N2	-0,70	0,48700
ESCO	0,59	0,55766
GW_REVAP	0,52	0,60624
SOL_ALB1	0,49	0,62119
SLSUBBSN	-0,48	0,63415
CH_N1	0,43	0,66888
SOL_Z	-0,33	0,74394
GW_DELAY	-0,31	0,75678
SURLAG	-0,13	0,89340
CH_K2	0,05	0,95685

Fonte: autora

Os parâmetros BIOMIX (eficiência de mistura biológica), CANMX (armazenamento de água máximo na copa das árvores), EPCO (fator de compensação de crescimento da planta), CN2 (valor de curva número da umidade na condição II), RCHRG_DP (fração de percolação para o aquífero profundo) também foram considerados importantes para a calibração da vazão diária no modelo SWAT.

Três dos seis parâmetros mais importantes apareceram como fundamentais, tanto para a calibração diária quanto para a mensal. Destaca-se que o parâmetro GWQMN esteve entre os seis principais para a calibração mensal, mas não mostrou importância na calibração da vazão diária. Houve ainda, outras divergências de importância entre os parâmetros para as diferentes

escalas de tempo, como por exemplo, o parâmetro SOL_AWC e GW_REVAP; conforme pode ser observado na Tabela 38.

Tabela 38 - Rank de sensibilidade dos parâmetros em relação à simulação da vazão diária e mensal na bacia do Taboão, considerando a estatística *p-Value* e; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006)

Calibração vazão diária				Calibração vazão mensal			
Parâmetro	p-Value	Ranking	Classificação importância	Parâmetro	p-Value	Ranking	Classificação importância
LAT_TTIME	0,00163	1	muito importante	CANMX	1,969E-77	1	muito importante
BIOMIX	0,05330	2	importante	LAT_TTIME	1,232E-64	2	importante
CANMX	0,07020	3	importante	RCHRG_DP	1,134E-21	3	importante
EPCO	0,11189	4	importante	GWQMN	1,805E-16	4	importante
CN2	0,11664	5	importante	SHALLST	3,006E-09	5	importante
RCHRG_DP	0,14170	6	importante	HRU_SLP	0,00023	6	importante
BLAI	0,29220	7	ligeiramente importante	SOL_K	0,01378	7	ligeiramente importante
CH_N1	0,33608	8	ligeiramente importante	SOL_AWC	0,01553	8	ligeiramente importante
SLSOIL	0,34377	9	ligeiramente importante	CN2	0,02970	9	ligeiramente importante
CH_N2	0,35420	10	ligeiramente importante	ALPHA_BF	0,04601	10	ligeiramente importante
ALPHA_BF	0,36295	11	ligeiramente importante	SLSOIL	0,07078	11	ligeiramente importante
GW_REVAP	0,37457	12	ligeiramente importante	OV_N	0,16816	12	ligeiramente importante
SLSUBBSN	0,37475	13	ligeiramente importante	BLAI	0,17165	13	ligeiramente importante
CH_K1	0,41225	14	ligeiramente importante	REVAPMN	0,28053	14	ligeiramente importante
SOL_K	0,41849	15	ligeiramente importante	BIOMIX	0,29833	15	ligeiramente importante
SHALLST	0,44298	16	ligeiramente importante	CH_K1	0,35951	16	ligeiramente importante
REVAPMN	0,45130	17	ligeiramente importante	EPCO	0,46429	17	ligeiramente importante
OV_N	0,46112	18	ligeiramente importante	CH_N2	0,48700	18	ligeiramente importante
HRU_SLP	0,47970	19	ligeiramente importante	ESCO	0,55766	19	ligeiramente importante
ESCO	0,55099	20	sem importância	GW_REVAP	0,60624	20	sem importância
SOL_ALB	0,73126	21	sem importância	SOL_ALB	0,62119	21	sem importância
SURLAG	0,77787	22	sem importância	SLSUBBSN	0,63415	22	sem importância
SOL_Z	0,84521	23	sem importância	CH_N1	0,66888	23	sem importância
GW_DELAY	0,84784	24	sem importância	SOL_Z	0,74394	24	sem importância
GWQMN	0,85830	25	sem importância	GW_DELAY	0,75678	25	sem importância
CH_K2	0,95153	26	sem importância	SURLAG	0,89340	26	sem importância
SOL_AWC	0,97189	27	sem importância	CH_K2	0,95685	27	sem importância

Fonte: autora

Os parâmetros classificados da posição 7 a 19 (Tabela 38) podem ser considerados ligeiramente importantes para a realização da calibração do modelo. Já os parâmetros classificados acima da posição 20 foram considerados como “sem importância” e, dessa forma, puderam ser desconsiderados na etapa de calibração do modelo.

Dos parâmetros identificados nesse estudo como mais sensíveis ou com alguma sensibilidade, utilizados para a posterior calibração da hidrologia na bacia do Taboão, o CN2 também foi apontado em análises de sensibilidade de 33 dos 37 estudos realizados no Brasil, e em 13 das 16 pesquisas realizadas na região sul do país, conforme descrito na Tabela 5; quando,

geralmente, é descrito entre os sete parâmetros mais importantes. Já o LAT_TTIME foi destacado como de alguma sensibilidade em 3 dos estudos desenvolvidos no Brasil, sendo 2 deles realizados na região sul. Enquanto que, o BIOMIX foi considerado com alguma sensibilidade em 10 pesquisas brasileiras (5 na região sul); e o parâmetro CANMX foi reportado como de alguma sensibilidade em 24 estudos realizados, sendo 14 deles relativos a simulações desenvolvidas em bacias da região sul.

Frequentemente, o parâmetro EPCO também está entre os mais sensíveis apontados em estudos brasileiros (13 situações reportadas na Tabela 5), e mais especificamente na região sul (5 de 16 estudos avaliados). Por outro lado, o RCHRG_DP não é um parâmetro rotineiramente apontado entre os mais sensíveis para simulação da hidrologia no Brasil, sendo observado em apenas 6 dos 33 estudos (2 deles na região sul), que o reportaram entre aqueles de alguma sensibilidade para a simulação dos processos hidrológicos.

Em contrapartida, entre os parâmetros classificados como “sem importância” nessa pesquisa, encontrou-se parâmetros que são, usualmente, considerados como de alguma importância para a calibração da hidrologia do Brasil, segundo estudos apontados na Tabela 5.

Há que se destacar, no entanto, que pode ter contribuído para isso o fato de que, dos 27 parâmetros analisados, apenas os parâmetros BIOMIX, BLAI, SLSUBBSN, SHALLST, OV_N, HRU_SLP, CH_K2, SOL_Z, SOL_ALB, CH_N1 e CH_K1 ainda não haviam sido previamente calibrados em estudo realizado por Depiné (2014). Isso porque se partiu dos valores sugeridos pela autora como opção de “valor inicial” na simulação realizada previamente no modelo SWAT, cujos resultados foram, posteriormente, utilizados para a análise de sensibilidade e calibração no SWAT-CUP.

Na Tabela 39 são apresentados os intervalos de variação, os valores iniciais e os valores calibrados (valores finais) dos parâmetros, considerando a simulação dos processos hidrológicos na bacia do Taboão, em um passo de tempo diário e mensal. Todos os demais parâmetros foram mantidos iguais aos valores padrão (*default*) do modelo SWAT.

As estatísticas da simulação dos processos hidrológicos, para o período de calibração (2013, 2014 e 2016) e de verificação (2011 e 2015) do modelo SWAT, estão listadas na Tabela 40, considerando um passo de tempo mensal e diário. O NS para a calibração e a verificação do escoamento mensal foi igual a 0,78 e 0,64, com PBIAS de 6,40% e -5,8% e RSR de 0,47 e 0,60, respectivamente. Essas estatísticas classificam o modelo como de desempenho “Muito Bom” para o processo de calibração, e “Satisfatório” para a verificação, conforme critérios definidos por Moriasi et al. (2007).

Tabela 39 - Intervalo de variação, valores iniciais e valores calibrados dos parâmetros incluídos no processo de calibração do modelo SWAT.

Parâmetro	Descrição	Faixa de variação	Valor inicial	Valor calibrado-mensal	Valor calibrado-diário
ALPHA_BF	constante de recessão do escoamento de base (dias)	0 --- 1	0,0496	0,627	0,719
BIOMIX	eficiência de mistura biológica	±0,2**	default	-0,040	0,282
BLAI	máximo de área foliar potencial da cultura	±0,2**	default	0,127	0,106
CANMX	armazenamento de água máximo na copa das árvores (mm)	0 --- 150	40,0	135,029	53,820
CH_K1	condutividade efetiva dos canais tributários (mm/h)	±0,2**	default	0,084	0,120
CH_K2	condutividade efetiva do canal principal (mm/h)	±0,2**	default	-0,076	0,014
CH_N1	coeficiente de rugosidade de Manning dos canais tributários	±0,2**	default	0,098	-0,130
CH_N2	coeficiente de rugosidade de Manning do canal principal	±0,2**	default	-0,339	-0,107
CN2	valor de curva número da umidade na condição II	±0,2**	default	0,278	0,004
EPCO.bsn	fator de compensação de crescimento da planta	0 --- 1	0,3	0,650	0,394
ESCO.bsn	fator de compensação da taxa de evaporação de água no solo	0 --- 1	0,7	0,052	0,623782
GW_DELAY	mar/14	0 --- 500	60,0	138,587	0,252
GW_REVAP	coeficiente que controla o fluxo de água da zona saturada para a não saturada	0.02 --- 0.2	0,2	0,123	0,065
GWQMN	nível limite da água no aquífero raso para a ocorrência de fluxo de base (mm)	0 --- 5000	4000,0	2937,605	2,880
HRU_SLP	média da declividade de cada HRU (m/m)	±0,2**	default	0,149	-0,048
LAT_TTIME	tempo necessário para o retorno do fluxo lateral (dias)	0 --- 180	31,0	26,185	35,892
OV_N	coeficiente de rugosidade de Manning para escoamento na superfície	±0,2**	default	-0,073	0,137
RCHRG_DP	fração de percolação para o aquífero profundo (fração)	0 --- 1	0,9	0,009	0,094
REVAPMN	profundidade limite de água no solo para a ocorrência de ascensão da água à zona não saturada (mm)	0 --- 1000	0,5	894,555	103,374969
SHALLST	profundidade inicial da água no aquífero raso (mm)	0 --- 5000	10,0	3589,628	1654,799
SLSOIL	comprimento da declividade para o escoamento subsuperficial (m)	±0,2**	3,0	0,003	-0,012675
SLSUBBSN	comprimento de rampa médio para a sub-bacia (m)	±0,2**	50,0	-0,119	-0,147
SOL_ALB	albedo	±0,2**	*	0,128	0,327
SOL_AWC	água disponível no solo (mm/mm)	±0,2**	*	-0,257	-0,009
SOL_K	condutividade hidráulica saturada (mm/h)	±0,2**	*	0,185	-0,533
SOL_Z	profundidade da camada (mm)	±0,2**	*	-0,121	-0,231
SURLAG.bsn	coeficiente de atraso (lag) do escoamento superficial (dias)	1 --- 24	9,0	8,343	7,569

* Parâmetro variável, conforme a camada e o tipo de solo. Utilizados valores prévios descritos em Depiné (2014) e apresentados na Tabela 13
 **± 0, 2 ou ±20% de variação em relação ao parâmetro inicial.

Fonte: autora

Tabela 40 - Estatísticas de desempenho do modelo SWAT para os processos hidrológicos na bacia do Taboão, no período de calibração e de verificação; considerando um passo de tempo mensal e diário

Estatísticas	Vazão mensal			Vazão diária		
	Calibração	Verificação	Média	Calibração	Verificação	Média
Simulada						
Média	2,80	3,21	3,01	2,53	3,11	2,82
Desvio Padrão	0,95	1,18	1,07	1,40	1,73	1,57
Observada						
Média	3,00	3,04	3,02	2,86	3,07	2,97
Desvio Padrão	1,28	1,29	1,29	1,88	2,14	2,01
R² (>0,6)*	0,83	0,67	0,75	0,76	0,68	0,72
NS (>0,5)*	0,78	0,64	0,71	0,72	0,68	0,70
PBIAS (<±25%)*	6,40	-5,80	0,30	11,50	-1,30	5,10
RSR (≤0,70)*	0,47	0,60	0,54	0,53	0,56	0,55

* Estatísticas mínimas para desempenho satisfatório do modelo, conforme Moriasi et al. (2007)

Fonte: autora

Brighenti, Bonumá e Chaffe (2016), ao realizarem um estudo na bacia de Rio Negrinho (SC) com objetivos semelhantes ao dessa pesquisa, encontraram resultados nessa mesma linha. Segundo esse estudo, os melhores resultados de NS para a simulação das vazões mensais foram iguais a 0,73 no processo de calibração e 0,63 na etapa de verificação do modelo SWAT; o que lhes permitiu classificar o modelo como de “Bom” desempenho na calibração e satisfatório na verificação.

Quanto a essa pesquisa, em específico, é possível interpretar que, para a escala mensal, o modelo conseguiu representar bem a tendência geral do comportamento do hidrograma na saída da bacia (Figura 42a,b), com valores simulados semelhantes aos valores observados (Figura 42d), e erros na estimativa da vazão simulada entre -1,5 e 2,0 m³/s (Figura 42c), tanto no processo de calibração quanto na verificação.

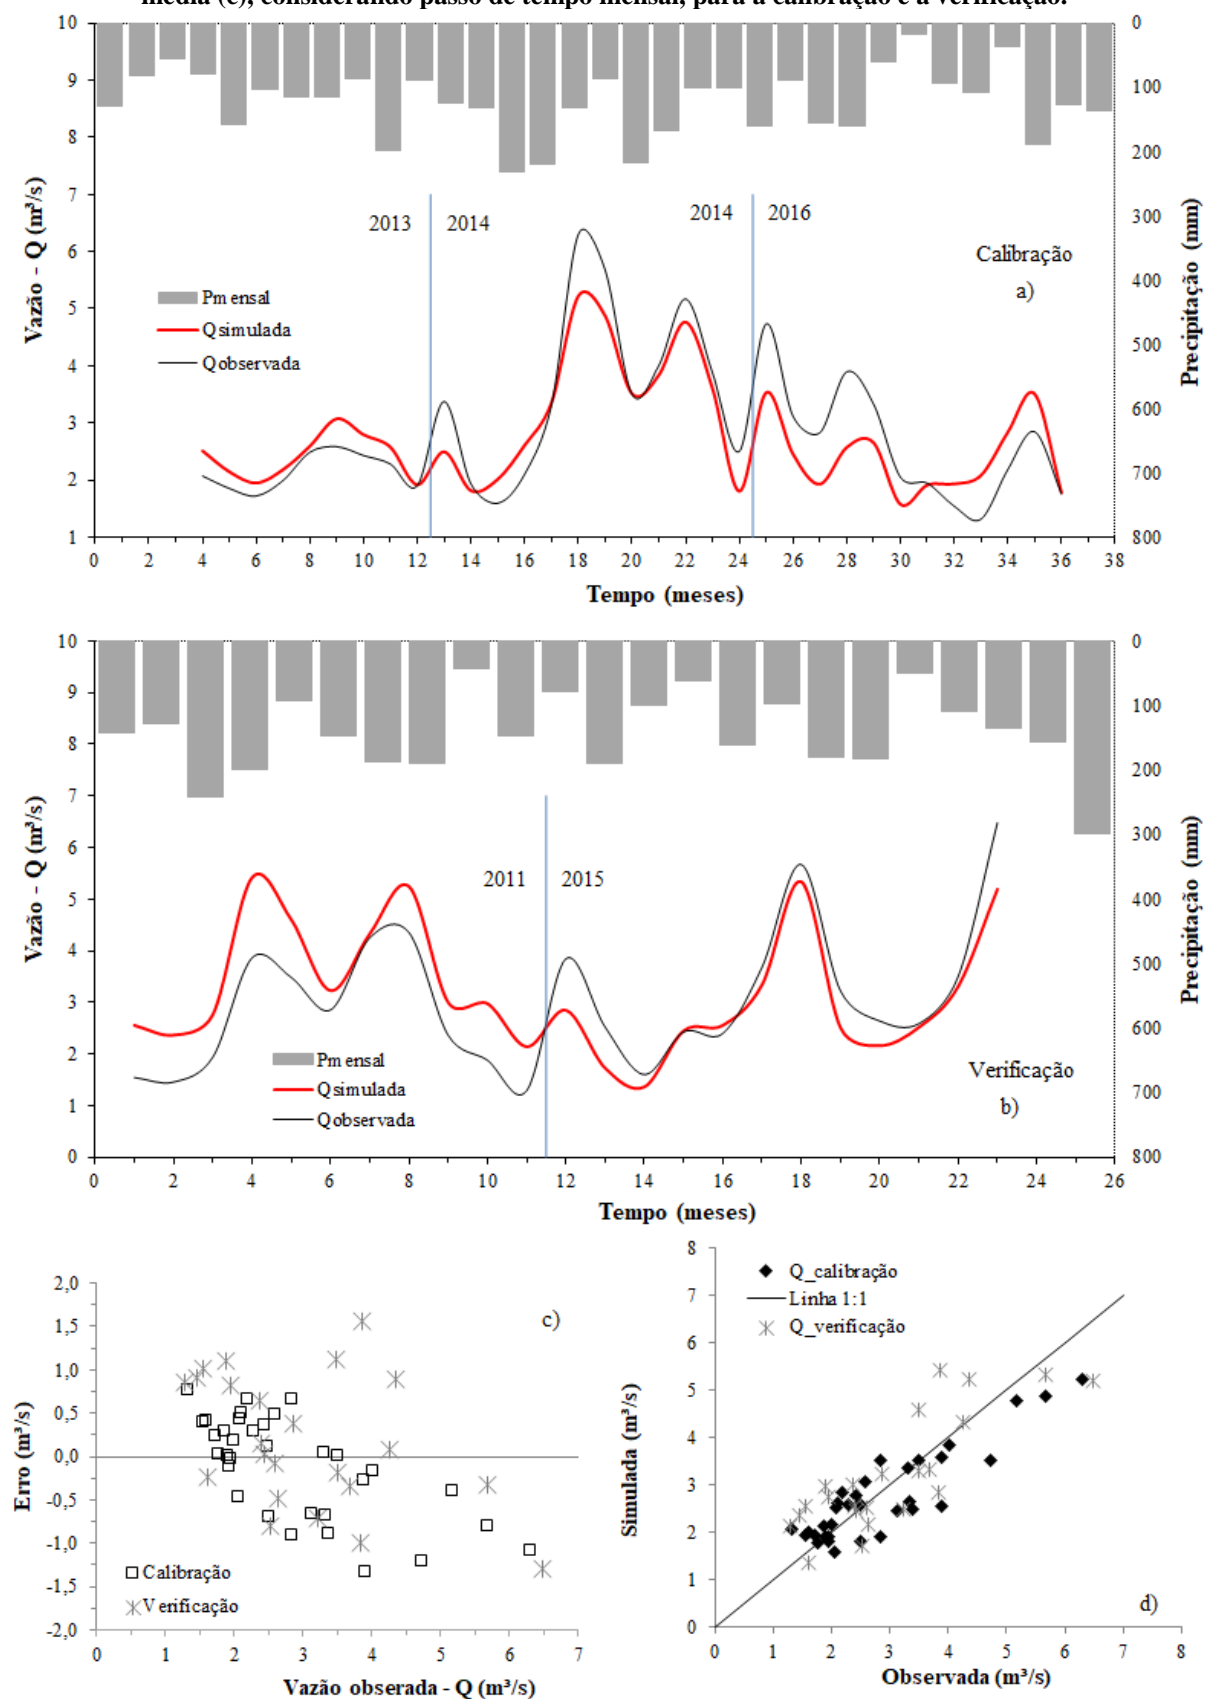
No entanto, apesar da sequência dos picos e dos períodos de recessão do hidrograma ter sido bem simulada, ocorreram alguns erros na magnitude dos valores de vazão estimados pelo modelo SWAT, com tendência geral à subestimativa (PBIAS positivo) dos dados simulados em relação aos observados na bacia para a série de calibração e, por outro lado, com tendência geral à superestimativa (PBIAS negativo) na série de verificação (Figura 42a,b).

As vazões médias mensais observadas foram da ordem de 3,00±1,28 m³/s para a calibração e de 3,04±1,29 m³/s na etapa de verificação, respectivamente. Já as vazões médias mensais simuladas foram iguais a 2,80±0,95 m³/s para a calibração, e 3,21±1,18 m³/s na verificação.

Na escala de tempo diária, o modelo SWAT mostrou desempenho menor para a calibração, em comparação ao passo de tempo mensal e, contrariamente, melhor desempenho no processo de verificação. O NS obtido foi igual a 0,72 e 0,68, RSR de 0,53 e 0,56 e; PBIAS igual a 11,50% e -1,30%, para as etapas de calibração e de verificação, respectivamente. Essas estatísticas permitiram classificar o modelo como de desempenho “Bom”, tanto para a calibração quanto para a verificação dos processos hidrológicos diários, conforme valores definidos por Moriasi et al. (2007) para o critério NS.

As estatísticas citadas indicaram, ainda, maior divergência em relação à média durante a calibração do modelo SWAT, para a vazão diária se comparada à vazão mensal; com RSR maior (maior divergência da média) e com tendência à subestimativa dos picos (PBIAS positivo).

Figura 42 - Resultados dos processos hidrológicos simulados no modelo SWAT: variação da vazão média simulada e observada em relação a precipitação ocorrida (a); vazão média simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados de vazão média (c), considerando passo de tempo mensal, para a calibração e a verificação.



Fonte: autora

Por outro lado, durante a verificação, o modelo mostrou-se mais adequado na escala diária em comparação à simulação em um passo de tempo mensal, com tendência geral à superestimativa dos picos (PBIAS negativo) e menor erro em relação à média (RSR menor); embora, os maiores valores de vazão tenham sido subestimados pelo modelo.

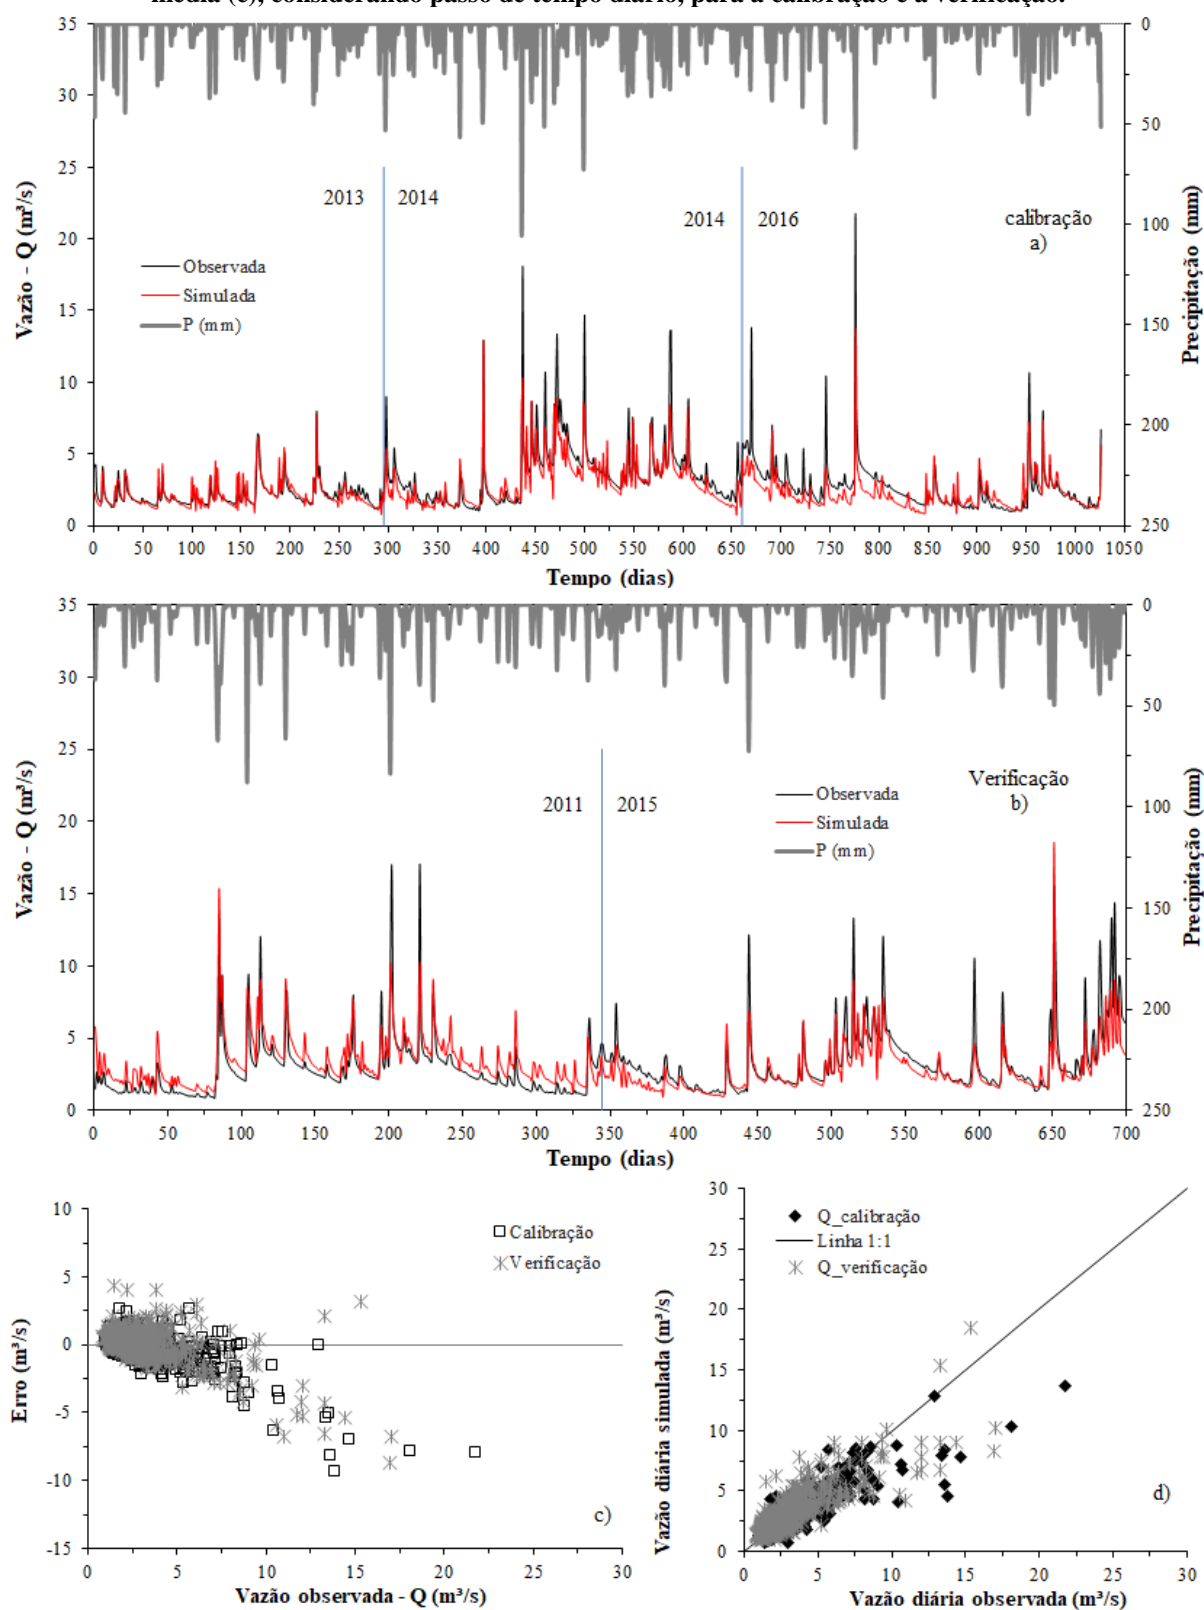
Há que se destacar, que a ocorrência de diferenças na simulação já era esperada, tendo-se em conta a existência de variabilidade espacial e temporal das precipitações na bacia, ao longo do tempo; o que tende a resultar, por consequência, também em maior variabilidade nos processos hidrológicos subsequentes.

Loitzenbauer e Adam (2009) corroboram que a distribuição temporal das chuvas na bacia do Taboão não é constante quando se consideram pequenos intervalos de tempo, como um ano, havendo variação nos valores para os diferentes meses. Em alguns meses (por exemplo: outubro, novembro e abril), a precipitação se distribui homoganeamente enquanto que, em outros, isso não ocorre. Na maioria das situações, quando a média da precipitação é mais elevada, a distribuição é mais homogênea, e vice-versa. Além disso, nos meses de maior escassez hídrica, a parte sudeste da bacia, comumente, concentra maior disponibilidade hídrica, enquanto na parcela a noroeste há maior escassez. No entanto, em termos gerais, quando se considera um grande período histórico de dados pluviométricos, a distribuição das precipitações na bacia pode ser considerada homogênea.

Os resultados desse estudo permitiram concluir, igualmente, que na escala diária o modelo também conseguiu representar bem o comportamento geral do hidrograma na saída da bacia (Figura 43a,b), na medida em que a sequência de ocorrência dos picos e dos períodos de recessão foi bem replicada pelo modelo. Os valores simulados foram semelhantes aos dados observados (Figura 43d), tanto no processo de calibração quanto na verificação; todavia ocorreram subestimativas dos picos mais elevados de vazão (Figura 43a,b).

As diferenças mais visíveis entre os valores monitorados e simulados foram verificadas para vazões mais elevadas (Figura 43c,d), sendo os erros mais distantes do eixo zero observados para valores a partir de 10 m³/s, ou seja, para os picos das vazões monitoradas. Na etapa de verificação, para o ano de 2011, frequentemente ocorreu superestimativa dos picos da vazão; enquanto que, para o ano de 2015, os valores das vazões máximas foram usualmente subestimados pelo modelo (Figura 43c,d). Isso se correlaciona às características climáticas e aos volumes de precipitação ocorridos em cada um dos anos citados, já que o ano de 2011 caracterizou-se como mais seco e o de 2015 como mais úmido.

Figura 43 - Resultados dos processos hidrológicos simulados no modelo SWAT: variação da vazão média simulada e observada em relação a precipitação ocorrida (a); vazão média simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados de vazão média (c), considerando passo de tempo diário, para a calibração e a verificação.



Fonte: autora

Conforme dados do INPE (<http://enos.cptec.inpe.br/>), para o período de análise dos processos hidrológicos na bacia (2011 a 2016), entre os anos de 2010 e início de 2011 existiu um período de La Niña, seguido de um período neutro entre 2012 e 2014 e, em seguida, um forte período de El Niño, de 2014 a 2016 (segunda maior intensidade registrada depois do El Niño de 1997-1998). No regime El Niño, as precipitações e a temperatura na região sul do Brasil, normalmente, ficam acima da média. Por outro lado, nos anos de ocorrência de La Niña, as precipitações na região tendem a ficar abaixo da média, com ocorrência de fortes estiagens em alguns locais. Na safra de 2012 (entre novembro e dezembro), apesar desse ano ser caracterizado como neutro, houve uma seca extrema na região da bacia, com impossibilidade de plantio em muitas das lavouras locais.

De modo geral, os valores médios de vazão para a simulação diária (Q_{sim}) também foram inferiores as vazões médias observadas (Q_{obs}) durante a calibração ($Q_{sim}=2,53\pm 1,40$ m³/s e $Q_{obs}=2,86\pm 1,88$ m³/s) e; superiores às vazões médias observadas para a etapa de verificação ($Q_{sim}=3,11\pm 1,73$ m³/s e $Q_{obs}=3,07\pm 2,14$ m³/s).

O valor do PBIAS, que diz respeito ao percentual de viés das vazões simuladas em relação às vazões observadas, ficou dentro da faixa dos resultados de desempenho “Muito Bom” ($PBIAS < \pm 10\%$), tanto na calibração quanto na verificação dos processos mensais. O mesmo se deu para a verificação da vazão na escala diária. Já para a etapa de calibração da vazão diária, o desempenho foi considerado “Bom” ($\pm 10\% \leq PBIAS < \pm 15\%$). De um ponto de vista interpretativo, quanto mais próximo de zero estiverem esses valores, mais adequado será esse modelo na estimativa dos processos simulados.

Análises do RSR (coeficiente de desvio padrão das observações) para as escalas mensal e diária da simulação, também mostraram um desempenho “Bom” do modelo para a calibração diária; assim como, para as etapas de verificação diária e mensal, com valores na faixa ($0,50 < RSR \leq 0,60$) proposta por Moriasi et al. (2007). Já no referente à etapa de calibração mensal, o modelo foi classificado como “Muito Bom” ($0,00 \leq RSR \leq 0,50$). Interpretativamente, quanto menor for o valor de RSR, melhor será o desempenho de um dado modelo para as simulações dos processos analisados.

Os erros na escala diária foram superiores aos encontrados para a escala mensal, tanto na calibração quanto na verificação, o que se justifica pela minimização da variação das vazões quando se emprega um passo de tempo mensal, que utiliza a vazão média diária para determinação do valor mensal, reduzindo, por conseguinte, a variação do hidrograma ocasionada pelos eventos ocorridos ao longo do mês. A variação em termos diário é maior pelo

fato de que a área de drenagem da bacia do Taboão é pequena, o que faz com que a resposta a um determinado evento de precipitação seja rápida, resultando em maior variabilidade dos processos na escala diária.

Os resultados obtidos para o PBIAS, NS e RSR para as simulações mensais e diárias confirmaram, portanto, que o modelo foi mais eficiente na calibração quando comparado à verificação; sendo que, na calibração, o modelo SWAT apresentou uma tendência geral de subestimar as vazões (PBIAS positivo), enquanto que na verificação, houve tendência geral à superestimativa (PBIAS negativo).

Diante dos resultados encontrados convém salientar que, nos processos de modelagem, é usual que os índices estatísticos determinados para o período de verificação sejam inferiores àqueles observados para o período de calibração do modelo, uma vez que os valores dos parâmetros são otimizados para o período usado na calibração (FUKUNAGA, 2015; LELIS et al., 2012; PINTO et al., 2013). Dessa forma, o período de verificação pode apresentar condições diferentes daquelas utilizadas para a estimativa dos parâmetros calibrados (FUKUNAGA, 2015), como ocorreu em parte do ano de 2011, utilizado nesse estudo.

Sem dúvida, a adequação do modelo para condições diferentes daquelas previstas na calibração representa um ponto crítico da modelagem, permitindo a caracterização definitiva de sua aplicabilidade para a simulação de condições futuras na bacia considerada (DURÃES, MELLO e NAGHETTINI, 2011).

No caso desse estudo, as estatísticas observadas nas simulações realizadas indicaram que o modelo SWAT pode ser utilizado, com bons resultados, para a estimativa dos processos hidrológicos na bacia, em uma escala de tempo mensal e diária; sendo possível a simulação de cenários futuros de uso e manejo do solo, para a previsão da influência de sua alteração sobre os processos hidrológicos. Não obstante, melhores resultados de desempenho poderiam ser obtidos pela separação da amostra em período seco e úmido, com posterior determinação dos parâmetros calibrados para cada período e características climáticas.

Brighenti, Bonumá e Chaffe (2016) reportaram melhoria no desempenho do modelo SWAT para a simulação de processos hidrológicos na bacia do Rio Negrinho (Santa Catarina) quando as séries de dados foram separadas em período úmido e seco para calibração e verificação. Os autores também perceberam que os anos úmidos (2008 a 2012) tinham calibrações e validações mais eficientes que os anos secos (2003 a 2007), comportando-se de maneira mais homogênea; sendo geralmente bem validados pelos dois períodos (seco e úmido).

Esse fato, segundo os autores, pode estar associado à escolha da função objetivo (NS) para calibração automática, a qual prioriza os valores mais altos de vazão.

Resultados encontrados em pesquisa de Depiné (2014), também realizada na bacia do Taboão, mostraram um NS na verificação de 0,86 e uma diferença entre dados observados e simulados (PBIAS) da ordem de 3,98%, quando empregados 16 pluviógrafos com entrada horária. Esse desempenho decaiu para NS=0,82, com PBIAS elevando-se a 4,1%, quando foram utilizados 8 pluviógrafos. Por fim, o NS diminuiu a 0,78 para 4 pluviógrafos (número igual ao usado nessa pesquisa), e a 0,75, com PBIAS elevando-se a 17,6%, quando apenas uma entrada de precipitação horária foi utilizada.

A autora destacou, portanto, que a redução na quantidade de pluviógrafos utilizados na simulação, ampliava as diferenças em relação às vazões observadas, reduzindo o desempenho do modelo (menor NS e maior PBIAS). Além disso, Depiné (2014) percebeu também, que o preenchimento prévio das falhas de precipitação horária, por meio de RNAs, elevava as estatísticas de desempenho do modelo SWAT para a previsão da vazão diária (NS=0,69 para 16 pluviômetros com falhas horárias).

Tecendo um comparativo dessa pesquisa com os desempenhos descritos por Depiné (2014) para a vazão, nas etapas de calibração e de verificação, no caso do uso de quatro pluviógrafos, com entradas horárias de precipitação e saída diária, é possível concluir que os resultados encontrados pela autora foram melhores do que os observados nesse estudo. As diferenças encontradas podem, em parte, ser justificadas pelo fato de Depiné (2014) ter utilizado, para as análises realizadas, séries de vazão com maior número de falhas, o que pode ter resultado em melhor representatividade do modelo, para o menor número de eventos utilizados, tendo em vista a possibilidade de menor variabilidade dos dados em comparação ao período total utilizado nessa pesquisa.

Além disso, os períodos analisados pela autora possuíam anos mais secos, se comparados aos anos analisados nesse estudo (2011, 2013 a 2016). Naquele estudo, foi utilizada a série de vazão de 11/01/2002 a 16/09/2004 para o processo de calibração do modelo, e o período de 01/01/2008 a 31/05/2011 para a verificação. Conforme já apresentado anteriormente, os anos de 2002-2003 foram classificados como de ocorrência de El Niño de intensidade moderada, enquanto que os anos de 2004-2005, 2006-2007 e 2009-2010 foram de El Niño de fraca intensidade. Já os anos de 2003-2004 e 2005-2006 foram enquadrados como neutros, e o ano 2007-2008 foi considerado ano de Lã Niña de alta intensidade (Figura 44).

Figura 44 - Ocorrência de El Niño e La Niña de 1877 a 2010

Ocorrência de El Niño

1877 - 1878	1888 - 1889
1896 - 1897	1899
1902 - 1903	1905 - 1906
1911 - 1912	1913 - 1914
1918 - 1919	1923
1925 - 1926	1932
1939 - 1941	1946 - 1947
1951	1953
1957 - 1959	1963
1965 - 1966	1968 - 1970
1972 - 1973	1976 - 1977
1977 - 1978	1979 - 1980
1982 - 1983	1986 - 1988
1990 - 1993	1994 - 1995
1997 - 1998	2002 - 2003
2004 - 2005	2006 - 2007
2009 - 2010	-

Legenda: Forte Moderada Fraco

Fontes de Informações

Rasmusson e Carpenter 1983, Monthly Weather Review, Ropelewski e Halpert 1987, Monthly Weather Review. Cold episode sources Ropelewski e Halpert 1989, Journal of Climate. Climate Diagnostics Bulletin. A intensidade dos ventos é baseada no padrão e magnitude das anomalias da TSM do Pacífico Tropical.

Ocorrência do La Niña

1886	1903 - 1904
1906 - 1908	1909 - 1910
1916 - 1918	1924 - 1925
1928 - 1929	1938 - 1939
1949 - 1951	1954 - 1956
1964 - 1965	1970 - 1971
1973 - 1976	1983 - 1984
1984 - 1985	1988 - 1989
1995 - 1996	1998 - 2001
2007 - 2008	-

Legenda: Forte Moderada Fraco

Fontes de Informações

Rasmusson e Carpenter 1983, Monthly Weather Review, Ropelewski e Halpert 1987, Monthly Weather Review. Cold episode sources Ropelewski e Halpert 1989, Journal of Climate. Climate Diagnostics Bulletin. A intensidade dos ventos é baseada no padrão e magnitude das anomalias da TSM do Pacífico Tropical.

Fonte: <http://enos.cptec.inpe.br/>

Por outro lado, nesse estudo, os anos de 2010 e 2011 apresentaram um período caracterizado como de La Niña, que foi seguido de um período neutro, entre 2012 e 2014 e, na sequência, por um forte período de El Niño de 2014 a 2016. Ou seja, os anos utilizados por Depiné (2014) trataram-se, pois, de períodos mais secos ou neutros em comparação a maioria dos anos utilizados nessa pesquisa (mais úmidos).

Sendo assim, os resultados desse estudo permitem inferir que, provavelmente, seria interessante realizar uma calibração para períodos secos e outra para períodos úmidos na bacia do Taboão, separando-se a série de dados, conforme chuva e níveis médios presentes; e também, considerando a ocorrência de situações de La Niña e El Niño para a divisão dos dados. Isso poderia melhorar os índices de desempenho da simulação dos processos hidrossedimentológicos com o modelo SWAT, na medida em que seria possível estabelecerem-se parâmetros específicos para cada um desses períodos climáticos.

Pesquisas desenvolvidas por outros autores em bacias hidrográficas brasileiras mostraram que o modelo SWAT tende a gerar melhores resultados para as simulações em escala

mensal e/ou anual, com a maioria dos desempenhos dos estudos classificados como “Muito Bom” ($NS > 0,75$). Enquanto que, os resultados em escala diária, apresentam menor desempenho, sendo a maior parcela dos estudos classificados com desempenho “Satisfatório” ($0,5 < NS \leq 0,65$); com apenas um pequeno percentual dos trabalhos com indicação de desempenho “Muito Bom” (GARBOSSA et al., 2011; BRESSIANI et al., 2015).

Estudo realizado por Bressiani et al. (2015) mostrou que, quase 95% das pesquisas efetuadas em bacias hidrográficas brasileiras relataram estatísticas mensais de NS para a calibração e/ou a verificação que atendem aos critérios considerados “Satisfatórios”, sendo 61% delas reportadas como de desempenho “Muito Bom” para a calibração. No entanto, na investigação reportada por esses autores, frequentemente, foram observados resultados mais fracos para as estatísticas de NS na calibração/verificação em escala diária; com 75% dos valores de NS sendo considerados “Satisfatório” e, apenas 25% alcançando critério de desempenho “Muito Bom”.

Acrescenta-se ainda, que a maioria das pesquisas brasileiras efetua, unicamente, a calibração dos processos hidrológicos/sedimentológicos (66% de 102 estudos), enquanto que, tão somente uma pequena parcela dessas realiza também a etapa de verificação (23%) da calibração efetuada. Isso se deve, sobretudo, ao fato de que mais de 70% desses estudos nacionais utilizam períodos menores do que cinco anos para a execução da calibração e/ou da verificação do modelo (BRESSIANI et al., 2015), o que pode ser um limitador para a melhoria do desempenho das simulações com o modelo SWAT no Brasil.

Nessa pesquisa, em específico, a calibração foi considerada com desempenho “Muito Bom” para a simulação das vazões mensais e com “Bom” desempenho para a simulação diária. Já na etapa de verificação das vazões mensais foi alcançado desempenho classificado como “Satisfatório”, enquanto que na simulação diária se encontrou um desempenho considerado “Bom”. Outros autores também reportaram valores semelhantes ou melhores do que os verificados nesse estudo, para a simulação dos processos hidrológicos mensais e/ou diários.

Durães, Mello e Naghettini (2011), por exemplo, avaliaram o desempenho do modelo SWAT para a simulação hidrológica na bacia do rio Paraopeba (Minas Gerais), obtendo NS iguais a 0,79, tanto na calibração quanto na verificação da vazão diária; o que classificou o modelo como “Muito Bom” para estimativas hidrológicas.

Andrade, Mello e Beskow (2013) relataram NS igual a 0,66 e 0,87 para a etapa de calibração e de verificação do escoamento diário, respectivamente, em pesquisa efetuada em

uma bacia da região do Alto Rio Grande (Minas Gerais). Esses autores empregaram dois anos para a calibração e um ano para a verificação do modelo.

Já Pinto et al. (2013) utilizaram o modelo SWAT para simular o escoamento e a concentração de sedimentos suspensos (CSS) na bacia de Lavrinha, na região de Mantiqueira (Minas Gerais). Os autores utilizaram 2 anos (setembro de 2006 a agosto de 2008) para a calibração do modelo e 2 anos para a sua verificação (setembro de 2008 a agosto de 2010). As simulações do escoamento diário resultaram em NS de 0,81 e 0,79 para os períodos de calibração e de verificação, respectivamente; qualificando o modelo como “Muito Bom”.

Resultados reportados por Melo Neto et al. (2014) para a estimativa dos processos hidrológicos diários em duas bacias hidrográficas, com diferentes escalas espaciais (32 km² e 4,7 km²), na região do rio Grande (Minas Gerais), mostraram NS de 0,58 e 0,71 na fase de calibração e de 0,46 na fase de verificação do modelo. O desempenho em microescala não foi considerado adequado.

Pereira et al. (2014), por sua vez, analisaram o desempenho do modelo SWAT para a simulação hidrológica em uma bacia hidrográfica na cidade de Domingos Martins (Espírito Santo), em uma escala de tempo diária, encontrando NS de 0,65 e 0,70 para os períodos de calibração e de verificação, respectivamente. Essas estatísticas classificaram o modelo como “Satisfatório” na calibração e “Bom” na verificação, possibilitando seu emprego para simulações futuras.

Fukunaga (2015) ponderou a capacidade do modelo SWAT para modelar o escoamento diário na bacia do rio Itapemirim (Espírito Santo), identificando valores de NS iguais a 0,75 e 0,67 para as etapas de calibração e de verificação, respectivamente; o que caracterizou o modelo SWAT como de “Bom” desempenho.

Eduardo et al. (2016) abordaram diferentes estratégias de calibração e de testes do modelo SWAT para a simulação hidrológica diária na bacia do Rio das Mortes (Minas Gerais). O desempenho do modelo foi considerado “Muito Bom” na calibração (NS=0,76) e “Bom” na verificação (NS=0,68), indicando a possibilidade de seu uso em situações futuras.

E por fim, Pereira et al. (2016), ao simularem o escoamento diário na bacia do Rio Pomba (região sudeste do Brasil), descreveram NS igual a 0,76, tanto para o período de calibração quanto para a etapa de verificação do modelo SWAT. Esse desempenho pode ser considerado como “Muito Bom”, também indicando a boa adequabilidade do modelo para análises futuras.

Na Tabela 41 são descritos os valores anuais médios para os componentes hidrológicos do balanço hídrico simulado pelo modelo SWAT, tais como, precipitação total ocorrida (P); escoamento superficial (SURQ); evapotranspiração real na bacia (ET); escoamento subsuperficial (LATQ); escoamento subterrâneo (GWQ) e volume de água propagado pelo canal (produção de água-WYLD). A produção de água representa a soma do escoamento superficial (SURQ), do escoamento subsuperficial ou água que flui lateralmente pelo perfil de solo e entra no canal (LATQ) e; da contribuição de água pelo escoamento subterrâneo (água que retorna do aquífero raso e entra no canal) (GWQ), descontadas as perdas pela água que é armazenada no solo nas HRUs (SW) ou percolada no solo (PERC), recarregando o aquífero.

Tabela 41 - Componentes hidrológicos médios anuais do balanço hídrico simulado no modelo SWAT

Ano	Estatística	PET (mm)	ET (mm)	SW (mm)	PERC (mm)	SURQ (mm)	LATQ (mm)	GWQ (mm)	WYLD (mm)
2011	Média	794,74	663,49	495,61	296,52	60,87	1163,87	221,11	1475,89
	Desvio padrão	10,43	10,95	12,94	115,93	36,08	120,31	105,50	26,02
	Mediana	798,56	660,99	495,57	253,80	57,10	1160,68	183,57	1479,08
	Mínimo	759,48	641,02	471,36	137,49	13,26	743,07	61,11	1438,28
	Máximo	799,48	684,34	527,08	717,16	161,90	1302,42	602,96	1514,31
2013	Média	938,68	738,03	514,94	131,50	11,76	602,23	100,11	725,69
	Desvio padrão	12,34	10,86	18,82	62,73	13,81	60,22	51,16	13,78
	Mediana	943,23	740,44	514,61	110,37	8,11	617,78	82,03	727,02
	Mínimo	896,95	708,00	476,30	47,03	0,49	390,59	26,83	700,18
	Máximo	944,22	754,30	564,33	359,30	61,46	682,08	286,30	750,66
2014	Média	1002,39	825,23	538,66	284,66	32,65	1104,72	218,79	1380,41
	Desvio padrão	13,23	16,88	15,96	113,39	29,41	119,56	102,33	24,34
	Mediana	1007,35	831,61	538,96	246,67	23,43	1105,95	181,22	1377,97
	Mínimo	957,65	776,94	508,62	126,61	5,73	696,39	61,02	1348,19
	Máximo	1008,20	842,23	563,54	689,47	134,80	1276,39	585,38	1436,47
2015	Média	925,66	798,70	566,84	282,83	39,91	1026,43	213,06	1302,61
	Desvio padrão	12,22	12,91	12,44	92,69	36,18	276,00	79,82	304,46
	Mediana	930,23	805,04	566,00	259,70	34,68	1130,85	200,83	1472,14
	Mínimo	884,36	763,10	547,48	128,95	1,78	412,73	72,70	792,66
	Máximo	931,03	809,95	590,70	451,50	153,96	1324,27	364,35	1511,42
2016	Média	947,69	791,34	553,91	175,36	23,63	874,10	128,18	1047,01
	Desvio padrão	12,50	20,31	20,69	61,31	23,02	247,39	50,27	268,32
	Mediana	952,36	801,49	555,91	169,26	15,02	986,73	122,16	1151,42
	Mínimo	905,41	750,55	513,82	76,27	0,21	345,80	41,87	594,44
	Máximo	953,19	812,21	583,37	289,71	98,30	1218,34	219,32	1364,89

As estatísticas foram determinadas com base nos resultados da simulação anual dos processos hidrológicos considerando, para cada ano, os valores calculados para cada uma das 23 sub-bacias em que a bacia do Taboão foi subdividida

Fonte: autora

A principal forma de escoamento na bacia do Taboão é via escoamento subsuperficial, sendo pequena a contribuição por escoamento superficial. Isso se justifica por ser predominante na bacia o uso do solo para agricultura, com prática do plantio direto; restando sobre a superfície do solo uma grande quantidade de palha, que retém a umidade, diminuindo a água que esco superficialmente.

Esse resultado é corroborado por estudo realizado por Oliveira (2006) e Oliveira, Castro e Goldenfum (2010), ambos desenvolvidos na bacia do Donato, uma sub-bacia dessa área de estudo. Os autores analisaram o balanço hídrico em um lisímetro com plantio direto (com palha) e outro com plantio convencional (sem palha), considerando as culturas de soja no verão e de trigo no inverno. Durante o período úmido foi observado que o escoamento superficial e a drenagem profunda apresentaram mesmo comportamento, entretanto, no lisímetro com palha, a drenagem profunda foi mais expressiva se comparada àquela verificada no lisímetro sem palha. Já o escoamento superficial foi maior no lisímetro sem palha, indicando que a cobertura da palha tende a atenuar o impacto das gotas de chuva, fazendo com que ocorra maior infiltração e escoamento subsuperficial. Em contrapartida, no lisímetro sem palha, o impacto sucessivo das gotas de chuva gerou a formação de uma fina camada adensada na superfície, dificultando a infiltração de água no solo e, conseqüentemente, aumentando o volume do escoamento superficial.

Castro et al. (1999), por sua vez, analisaram os dados de escoamento superficial, de 22/08/1992 a 18/09/1993, em parcelas de solo de 1 m² na sub-bacia do Donato, sob chuva natural, com cultura de soja no verão e de aveia no inverno. Os autores avaliaram o escoamento para a prática de plantio direto e convencional, constatando que, no plantio convencional, o escoamento superficial foi de 16%, e para o plantio direto foi de 6%. As comparações realizadas mostraram, ainda, que a prática de plantio direto resultou em decréscimo do escoamento superficial nas encostas, com significativa diminuição da perda de solo e da erosão, tanto laminar como linear, na escala da parcela e da bacia. No entanto, foram observados incrementos no fluxo subsuperficial e a progressão de algumas voçorocas, apesar das alterações das práticas agrícolas realizadas; o que foi atribuído à influência exercida por fortes eventos de chuva e às evidências de fluxo subsuperficial sob a forma de *pipping*.

As voçorocas e ravinas, resultantes da atividade antrópica na região, configuram uma rede, comumente, conectada aos canais de drenagem. Nas cabeceiras dos cursos d'água da bacia, em declividades superiores a 15%, há predomínio do fluxo concentrado relacionado, sobretudo, às ravinas resultantes do cultivo do solo e; nas declividades inferiores a 5%,

predomina o fluxo subsuperficial (MENDIONDO et al., 1998). É importante salientar que a maior parcela da área da bacia é caracterizada por declividades inferiores à declividade média de 8%, o que ratifica a predominância do escoamento do tipo subsuperficial, conforme estudos realizados na bacia do Taboão ou em suas sub-bacias, citados ao longo dessa discussão.

Há que se considerar, igualmente, que a grande maioria dos solos presentes na bacia do Taboão são os Latossolos, que são caracterizados pela elevada profundidade e, em geral, pela alta permeabilidade e condutividade hidráulica. Essas características atribuem a esse solo melhores índices de infiltração e de armazenamento de água, diminuindo, por consequência, o escoamento superficial; o que foi observado nas simulações hidrológicas com o modelo SWAT.

4.9.2 Análise de sensibilidade, calibração e verificação da produção de sedimentos na bacia do Taboão

Com todos os ajustes anteriores finalizados e o modelo previamente calibrado para os processos hidrológicos, realizou-se a simulação da produção de sedimentos para o período de 2013 a 2015. Considerando-se a série total de dados disponíveis, o NS obtido foi igual a -0,03 e o PBIAS foi de 98,68% para a simulação da produção de sedimentos diária, decaindo para NS=-0,65 e PBIAS=84,55% para a simulação dos processos mensais. Tais resultados indicaram, portanto, a inadequabilidade do modelo em prever a produção de sedimentos diária e mensal (NS<0,50 e PBIAS>±25%), após realização da calibração dos processos hidrológicos na bacia do Taboão, demandando a necessidade de realização de calibração do modelo também para a produção de sedimentos na bacia.

Para a análise de sensibilidade e calibração do modelo SWAT, em termos da produção de sedimentos na bacia, foram considerados 21 parâmetros relacionados, unicamente, aos processos sedimentológicos.

Na Tabela 42 é apresentada a análise de sensibilidade dos parâmetros em relação à simulação da produção de sedimentos mensal na bacia do Taboão, o *rank* de sensibilidade dos parâmetros, considerando a estatística *p-Value* e, a classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006). Na Tabela 43 são expostas essas mesmas informações para as simulações em um passo de tempo diário.

Em ambos os passos de tempo, o parâmetro com maior sensibilidade no cálculo dos sedimentos foi o PRF (fator de ajuste da taxa de pico para o aporte de sedimentos no canal principal), seguido do SPCON (parâmetro linear para o cálculo da quantidade máxima de reentrada de sedimentos no aporte ao canal). O terceiro e o quarto parâmetros com maior efeito

sobre a simulação dos sedimentos relacionaram-se à erosão no canal (CH_COV1 e CH_COV2), indicando a erodibilidade do canal e o fator de cobertura vegetal no canal.

Tabela 42 - Análise de sensibilidade e rank de sensibilidade dos parâmetros em relação à simulação da produção de sedimentos mensal na bacia do Taboão, considerando a estatística *p-Value* e; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006)

Calibração da produção de sedimentos mensal				
Parâmetro	t-Stat	p-Value	Ranking	Classificação importância*
PRF_BSN	-14,7897813	0,000E+00	1	muito importante
SPCON	-20,7960121	0,000E+00	2	importante
CH_COV1	-5,4394843	8,500E-08	3	importante
CH_COV2	-5,0086235	0,0000008	4	importante
USLE_K	2,4646055	0,0140671	5	importante
RSDIN	2,3436456	0,0195051	6	importante
SPEXP	2,0498508	0,0409241	7	ligeiramente importante
CH_BNK_BD	1,9923415	0,0469019	8	ligeiramente importante
CH_ERODMO	-1,7865412	0,0746453	9	ligeiramente importante
CH_BNK_TC	1,5463804	0,1226745	10	ligeiramente importante
ADJ_PKR	1,3219676	0,1868112	11	ligeiramente importante
USLE_P	1,2771314	0,2021759	12	ligeiramente importante
CH_BED_KD	-1,1113509	0,2669760	13	ligeiramente importante
CH_BED_BD	0,8580384	0,3913013	14	ligeiramente importante
CH_D50	-0,7930651	0,4281334	15	ligeiramente importante
CH_BNK_D50	0,6876936	0,4919793	16	ligeiramente importante
LAT_SED	0,5712413	0,5681045	17	ligeiramente importante
USLE_C	-0,4960765	0,6200685	18	ligeiramente importante
CH_BED_TC	-0,1962581	0,8444916	19	ligeiramente importante
CH_BNK_KD	-0,0805430	0,9358391	20	sem importância
CH_BED_D50	0,0524093	0,9582244	21	sem importância

*Classificação realizada em função da estatística *p-Value*, considerando *t-Stat* apenas para os dois primeiros parâmetros, que resultaram em mesmo *p-Value*

Fonte: autora

Na sequência, com algumas variações de posição, entre a produção diária e a mensal, apareceram os parâmetros SPEXP (parâmetro exponencial para o cálculo da reentrada de sedimentos no aporte ao canal), a erodibilidade do solo (USLE_K) e, o parâmetro relacionado ao material residual depositado nos primeiros 10 mm do solo (RSDIN); sendo esses dois últimos relativos à produção de sedimentos na paisagem.

Os parâmetros de práticas agrícolas (USLE_P) e de cobertura do solo (USLE_C) que, comumente, foram apontados como os mais importantes nos estudos apresentados na Tabela 6, nessa pesquisa em específico, foram considerados apenas como “ligeiramente importantes” na

estimativa da produção de sedimentos na bacia do Taboão, tanto em um passo de tempo mensal quanto diário.

Tabela 43 - Análise de sensibilidade e rank de sensibilidade dos parâmetros em relação à simulação da produção de sedimentos diária na bacia do Taboão, considerando a estatística *p-Value* e; classificação de importância dos parâmetros, conforme proposto por Van Griensven et al. (2006)

Calibração da produção de sedimentos diária				
Parâmetro	t-Stat	p-Value	Ranking	Classificação importância*
PRF	-14,5605698	0,000E+00	1	muito importante
SPCON	-19,0464139	0,000E+00	2	importante
CH_COV1	-4,8759148	1,477E-06	3	importante
CH_COV2	-4,5556055	0,0000066	4	importante
SPEXP	3,3645451	0,0008284	5	importante
USLE_K	2,3535101	0,0190011	6	importante
RSDIN	2,2009599	0,0282162	7	ligeiramente importante
CH_BNK_BD	1,9272218	0,0545443	8	ligeiramente importante
CH_ERODMO	-1,6713051	0,0953159	9	ligeiramente importante
CH_BNK_TC	1,4472958	0,1484696	10	ligeiramente importante
ADJ_PKR	1,3540034	0,1763751	11	ligeiramente importante
CH_BED_KD	-1,3260638	0,1854518	12	ligeiramente importante
CH_BED_BD	0,9709698	0,3320544	13	ligeiramente importante
USLE_P	0,9687922	0,3331388	14	ligeiramente importante
CH_D50	-0,9224501	0,3567592	15	ligeiramente importante
CH_BNK_D50	0,7832038	0,4338953	16	ligeiramente importante
LAT_SED	0,7106272	0,4776618	17	ligeiramente importante
USLE_C	-0,4332530	0,6650264	18	ligeiramente importante
CH_BNK_KD	0,0911631	0,9274012	19	ligeiramente importante
CH_BED_D50	0,0715919	0,9429566	20	sem importância
CH_BED_TC	-0,0051709	0,9958764	21	sem importância

*Classificação realizada em função da estatística *p-Value*, considerando t-Stat apenas para os dois primeiros parâmetros, que resultaram em mesmo *p-Value*

Fonte: autora

Por outro lado, o parâmetro SPCON, que figurou como o segundo de maior sensibilidade nessa pesquisa, também foi citado como de grande sensibilidade na maioria dos estudos que investigaram a produção de sedimentos no Brasil, conforme resultados descritos na Tabela 6. Quando o parâmetro RSDIN foi avaliado nos estudos realizados em bacias brasileiras, usualmente, foi identificado como de grande sensibilidade, o que é bastante razoável para bacias caracterizadas como agrícolas em que há grande quantidade de material residual de uma safra para outra, a exemplo do que ocorre na bacia desse estudo.

Na Tabela 44 são descritos os intervalos de variação, os valores iniciais e os valores calibrados (valores finais) dos parâmetros, considerando a simulação dos processos sedimentológicos na bacia do Taboão, em um passo de tempo diário e mensal. Todos os demais parâmetros foram mantidos iguais aos valores padrão (*default*) do modelo SWAT.

Tabela 44 - Intervalo de variação, valores iniciais e valores calibrados dos parâmetros incluídos no processo de calibração do modelo SWAT, para um passo de tempo mensal e diário.

Parâmetro	Faixa de variação	Valor inicial	Valor calibrado mensal	Valor calibrado diário
ADJ_PKR	0--2	default	1,461557	1,197282
LAT_SED	0--50000	default	50432,41797	4234,63623
RSDIN	0 --- 55000	default	10791,58984	5052,0991
CH_COV1	-0,05---10	default	2,933313	5,199367
CH_COV2	-0,001---10	default	2,019842	6,481053
CH_ERODMO	0--5	default	2,369204	0,42692
USLE_C	±0,2**	default	0,125758	-0,268574
USLE_P	0--1	default	0,515982	0,043162
USLE_K	±0,2**	*	-0,497286	0,347719
CH_BNK_KD	0,001---3,75	default	3,954809	2,857672
CH_BED_KD	0,001---3,75	default	1,112966	0,868295
CH_BED_D50	0--10000	530	893,191711	7339,825684
CH_BNK_D50	0--10000	55	3211,628174	8008,590332
CH_BNK_TC	0--400	default	292,526672	313,248138
CH_BED_TC	0--400	default	173,796524	214,821075
CH_BNK_BD	1,1---1,9	default	1,178598	1,730668
CH_BED_BD	1,1---1,9	default	1,276754	2,104537
PRF	0 --- 2	default	0,153631	0,480855
SPEXP	0 --- 3	default	1,281772	2,164623
SPCON	0,0001---2	default	0,006593	0,005588
CH_D50	±0,2**	default	0,150033	0,035165

* Parâmetro variável, conforme a camada e o tipo de solo. Utilizados valores prévios descritos em Depiné (2014) e apresentados na Tabela 13

**± 0, 2 ou ±20% de variação em relação ao parâmetro inicial.

Fonte: autora

Há que se destacar, todavia, que a calibração automática utilizando a opção SUFI-2 resultou em uma faixa de variação (máximo-mínimo) para cada parâmetro calibrado. Dessa forma, os melhores parâmetros identificados nesse estudo (na coluna valor calibrado) tanto para a calibração da vazão (apresentada anteriormente) quanto para a produção de sedimentos, fornecem apenas um indicativo de uma combinação possível entre os diferentes parâmetros calibrados; não significando, portanto, uma solução única, mas sim, uma entre as possíveis combinações de valores para o conjunto de parâmetros analisados. Existe, portanto, diferentes combinações possíveis para os parâmetros, as quais poderiam resultar em um desempenho semelhante (ou mesmo superior) para a calibração e a verificação do modelo.

A opção utilizada para a simulação do transporte de sedimentos no canal foi a opção 1, variável CH_EQN=1, que corresponde ao método de Bagnold. Também se analisou a opção de simulação com o método de Yang (CH_EQN=4), que se mostrou menos adequado.

As estatísticas da produção de sedimentos para o período de calibração e de verificação do modelo SWAT, considerando um passo de tempo mensal e diário, estão listadas na Tabela 45.

Tabela 45 - Estatísticas de desempenho do modelo SWAT para a simulação da produção de sedimentos, no período de calibração (2013 e 2015) e de verificação (2014), considerando um passo de tempo mensal e diário

Estatísticas		Produção de sedimentos					
		Mensal (ton/mês)			Diária (ton/dia)		
		Calibração	Verificação	Média	Calibração	Verificação	Média
Simulada	Média	1231,05	1351,21	1291,13	56,25	55,48	55,87
	Desvio Padrão	750,99	650,09	700,54	93,23	68,26	80,75
Observada	Média	1062,98	1246,41	1154,70	34,50	40,98	37,74
	Desvio Padrão	1144,03	1011,43	1077,73	131,01	108,44	119,73
	R² (>0,6)*	0,72	0,77	0,75	0,68	0,40	0,54
	NS (>0,5)*	0,66	0,70	0,68	0,64	0,38	0,51
	PBIAS (<±55%)*	-15,80	-8,40	-12,10	-63,00	-35,40	-49,20
	RSR (≤0,70)*	0,58	0,55	0,57	0,60	0,79	0,70

* Estatísticas mínimas para desempenho satisfatório do modelo, conforme Moriasi et al. (2007)

Fonte: autora

O NS na calibração e na verificação da produção de sedimentos mensal foi igual a 0,66 e 0,70, com RSR igual a 0,58 e 0,55 e; PBIAS de -15,8% e -8,40%, respectivamente, sendo os resultados obtidos para a verificação (ano de 2014) superiores aos observados para a etapa de calibração (anos de 2013 e 2015) do modelo. Conforme critérios propostos por Moriasi et al. (2007), essas estatísticas classificaram o modelo como de desempenho “Bom” para o critério NS, RSR e PBIAS, durante a calibração. Já na etapa de verificação, o modelo foi classificado como de “Bom” desempenho para os critérios NS e RSR e “Muito Bom” desempenho para o critério PBIAS.

A produção de sedimentos média mensal simulada pelo modelo SWAT foi da ordem de 1231,05±750,99 ton/mês para a etapa de calibração (2013 e 2015) e de 1351,21±650,09 ton/mês na verificação (2014), respectivamente. Já as produções médias mensais observadas no monitoramento realizado foram iguais a 1062,98±1144,03 ton/mês para a calibração, e 1246,41±1011,43 ton/mês na verificação.

Para a escala mensal, o modelo conseguiu representar razoavelmente a tendência geral da variação temporal do sedimentograma na saída da bacia (Figura 45a,b) no ano de 2015, com

valores simulados mais próximos aos observados para as menores produções de sedimento e erros mais elevados na estimativa dos maiores picos (Figura 45c,d).

Por outro lado, para o ano de 2013, essa tendência de variação da produção de sedimentos na bacia, ao longo do tempo, não foi bem representada (Figura 45a,b), com maiores erros entre valores simulados e observados (Figura 45c,d).

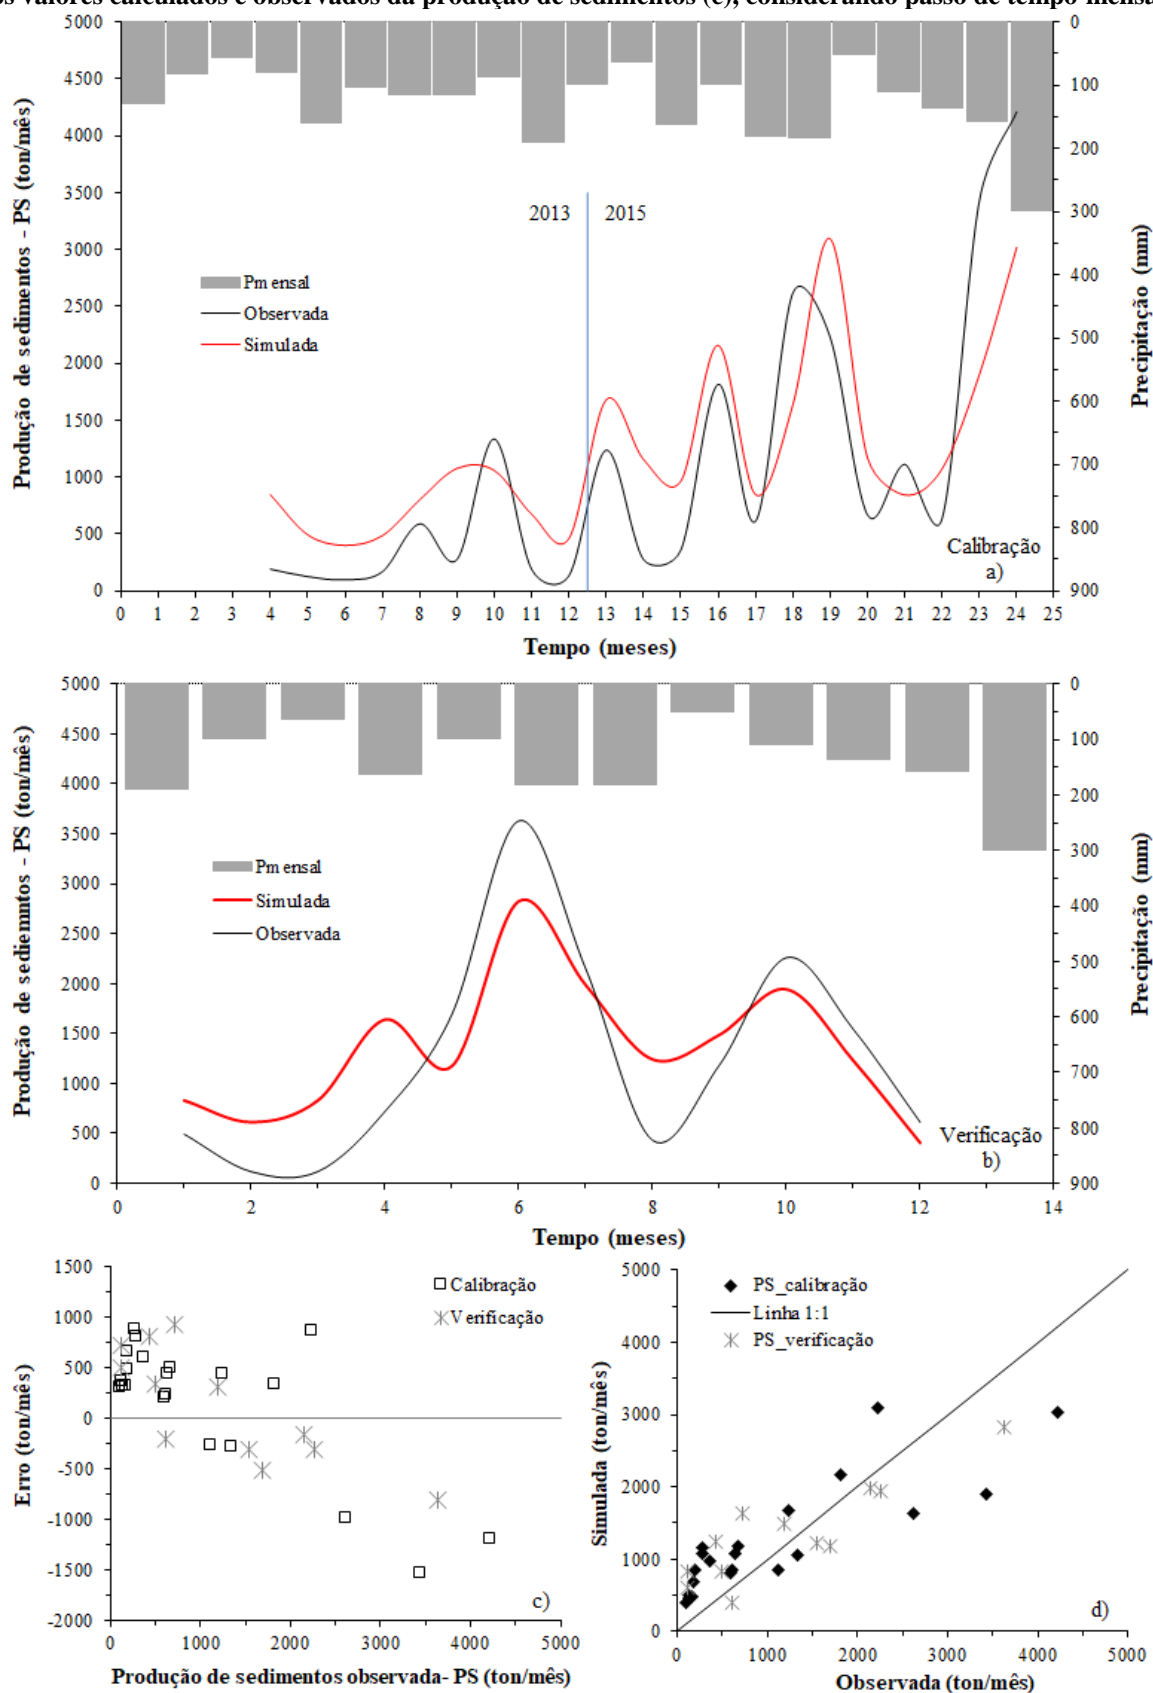
Houve tendência geral à superestimativa (PBIAS negativo) dos valores simulados em relação aos observados na bacia (Figura 45a,c); tanto na etapa de calibração quanto na verificação, para os diferentes anos analisados, embora na verificação os maiores picos tenham sido subestimados pelo modelo. Os erros na estimativa da produção de sedimentos mensal simulada oscilaram entre -1530 e 930 ton/mês (Figura 45c). As maiores divergências entre os valores monitorados e simulados pelo modelo foram verificadas para os valores mais elevados da produção de sedimentos observada, sendo os erros mais distantes do eixo zero verificados para valores a partir de 2500 ton/mês (Figura 45c,d).

Na escala de tempo diária, o NS obtido foi igual a 0,64, com RSR de 0,60 e PBIAS igual a -63,00% para a etapa de calibração, classificando o modelo como “Satisfatório” para as estatísticas NS e RSR e “Insatisfatório” para o critério PBIAS, conforme limites definidos por Moriasi et al. (2007). Na verificação, por outro lado, o modelo foi classificado como “Insatisfatório” para os critérios NS e RSR e “Satisfatório” para o critério PBIAS, com estatísticas NS=0,38, RSR=0,79 e PBIAS=-35,40%.

As estatísticas citadas indicaram, ainda, maior divergência dos valores calculados em relação à média, durante a calibração e a verificação do modelo SWAT para a produção de sedimentos em escala diária, se comparada ao passo de tempo mensal. O RSR observado foi mais elevado para os dados diários e também, ocorreu maior tendência geral à superestimativa da maioria dos valores de produção de sedimentos (PBIAS negativo superior ao mensal), embora os picos mais elevados tenham sido, frequentemente, subestimados pelo modelo.

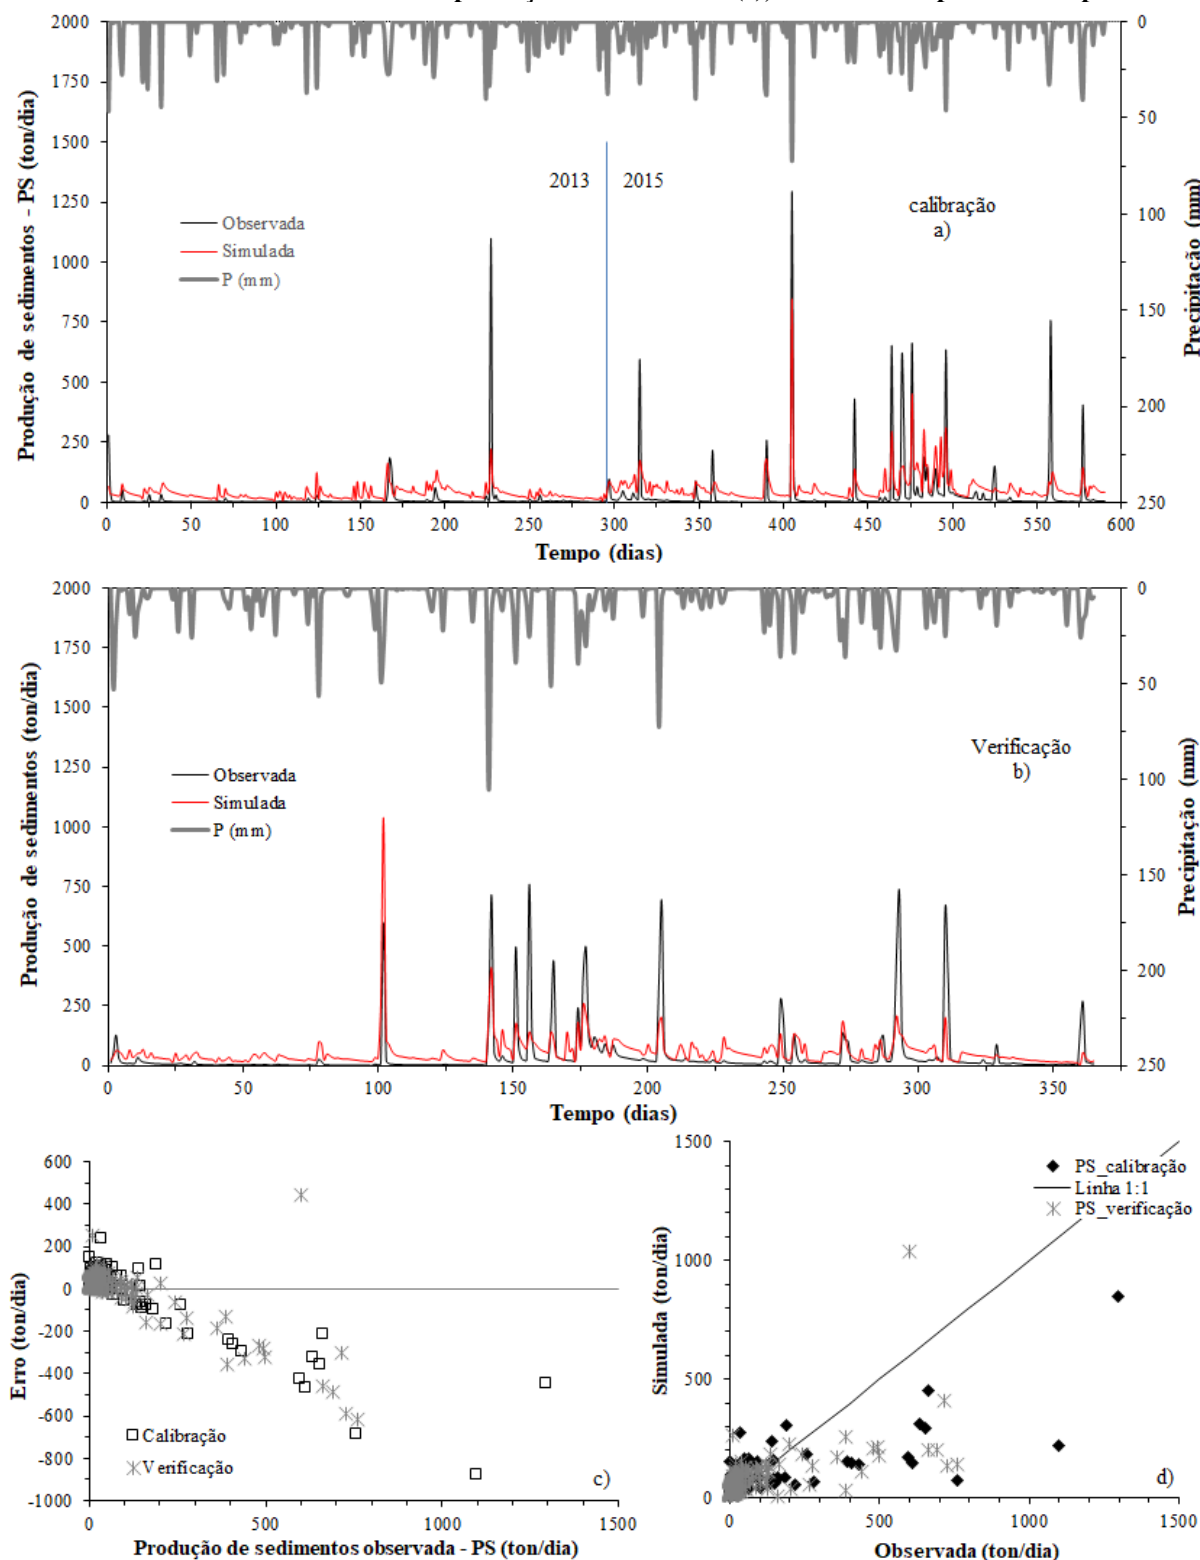
Os resultados desse estudo permitiram concluir, igualmente, que na escala diária, embora o modelo tenha conseguido representar razoavelmente a tendência temporal geral do comportamento do sedimentograma na saída da bacia, a magnitude dos picos é comumente subestimada pelo modelo enquanto que, os menores valores de produção de sedimentos são superestimados (Figura 46a,b); gerando a tendência final à superestimativa (PBIAS negativo) dos dados simulados, tanto no processo de calibração quanto na etapa de verificação. Ocorreram, portanto, divergências na produção de sedimentos simulada em relação à observada (Figura 46d), com erros na estimativa variando entre 237 e 900 ton/dia (Figura 46c).

Figura 45 - Resultados da calibração e da verificação da produção de sedimentos simulados no modelo SWAT: variação da produção de sedimentos simulada e observada em relação a precipitação ocorrida (a); produção de sedimentos simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados da produção de sedimentos (c), considerando passo de tempo mensal.



Fonte: autora

Figura 46 - Resultados da calibração e da verificação da produção de sedimentos simulados no modelo SWAT: variação da produção de sedimentos simulada e observada em relação a precipitação ocorrida (a); produção de sedimentos simulada e observada em relação a reta de ajuste ideal (b) e; erro verificado entre os valores calculados e observados da produção de sedimentos (c), considerando passo de tempo diário.



Fonte: autora

De modo geral, para os períodos de dados, os valores médios da produção de sedimentos para a simulação em escala diária (PS_{sim}) foram superiores às produções médias observadas (PS_{obs}), tanto para a calibração ($PS_{sim}=49,28\pm 105,87$ ton/dia e $PS_{obs}=34,5\pm 131,01$ ton/dia) quanto para a etapa de verificação do modelo SWAT ($PS_{sim}=56,25\pm 93,23$ ton/dia e $PS_{obs}=34,50\pm 131,01$ ton/dia). Isso ocorreu porque, comumente, as menores produções de sedimentos (mais comuns de ocorrer) são superestimadas, enquanto que os picos mais elevados (menos comuns de ocorrer) são bastante subestimados pelo modelo.

As estatísticas obtidas para o PBIAS, NS e RSR para as simulações mensais e diárias na bacia do Taboão confirmaram, portanto, que o modelo foi mais eficiente na verificação quando comparado à calibração na escala de tempo mensal e; por outro lado, menos eficiente na verificação para um passo de tempo diário. Em ambas as escalas, o modelo apresentou tendência geral a superestimar a produção de sedimentos (PBIAS negativo) na calibração e na verificação, embora a maioria dos picos mais elevados tenha sido subestimada para a escala diária (na calibração e na verificação) e também, para a etapa de verificação na escala mensal.

Os erros na escala diária foram superiores aos encontrados para a escala mensal, para a calibração e para a verificação, o que se justifica pela sequência de picos ocorridos na escala diária e ainda, pela rápida e elevada variação da produção de sedimentos diária em relação ao acumulado mensal, que é menos variável ao longo do tempo. De fato, o modelo não conseguiu acompanhar adequadamente essa subida no sedimentograma, subestimando significativamente os maiores picos diários e superestimando as menores produções, especialmente na série de verificação.

Possivelmente, o fato de o modelo utilizar a MUSLE para a determinação da erosão do solo e, conseqüentemente, da produção de sedimentos na bacia, tenha comprometido, em parte, os resultados gerados. Isso porque, essa equação calcula a erosão do solo apenas em ravinas, não considerando a erosão e o aporte de sedimentos provenientes do escoamento concentrado, como, por exemplo, os sedimentos advindos da erosão nas voçorocas e nos sulcos.

Entretanto, conforme já destacado ao longo das discussões tecidas nessa pesquisa, na bacia do Taboão, além da erosão nas ravinas, ainda existe uma pequena quantidade de voçorocas ativas, em diferentes pontos da bacia, as quais estão, em sua maioria, conectadas às redes de drenagem. Isso poderia gerar a facilidade de entrega dos sedimentos ao rio, a partir desses caminhos preferenciais; seja pela erosão ocorrida nas próprias voçorocas ou ainda, pela entrada de outras fontes de produções de sedimento da paisagem para esse caminho preferencial, através do escoamento.

Além disso, é preciso colocar que a MUSLE se utiliza do escoamento superficial e do potencial erosivo das chuvas para estimar a erosão do solo. Assim, quando se considera que existe grande quantidade de escoamento do tipo subsuperficial na bacia pesquisada é, então, possível inferir que esse fator pode também ter contribuído para a não representatividade das simulações, atuando como um limitador para a obtenção de melhor desempenho na estimativa da produção de sedimentos nessa bacia. Em momentos anteriores, as discussões realizadas ao longo dessa tese, evidenciaram que a introdução da prática de plantio direto na bacia do Taboão diminuiu o escoamento superficial, aumentando a infiltração da água no solo e o escoamento subsuperficial, bem como os processos de erosão interna (*pipping*) nos solos da bacia; processos esses que, possivelmente, não foram bem representados pelas rotinas da MUSLE e/ou outras rotinas de transporte/deposição de sedimentos contidas no modelo SWAT.

O modelo SWAT também possibilita o cálculo do escoamento pelo método da Curva Número (CN), com entrada de precipitação diária. Esse método, frequentemente, é o mais empregado nos estudos de simulação hidrossedimentológica com o modelo e, usualmente, seu emprego tem resultado em escoamento superficial mais elevado, com menor infiltração de água no solo; o que, em teoria, poderia melhorar a simulação dos processos sedimentológicos dependentes do escoamento superficial.

No entanto, testes realizados com esse método para a bacia do Taboão, não resultaram em boa estimativa dos processos hidrológicos, atingindo um NS na etapa de calibração da vazão diária de apenas 0,33 quando considerado para calibração o mesmo período utilizado para o método de Green & Ampt (empregado nessa pesquisa). Este último método, conforme já descrito anteriormente, resultou em NS igual a 0,72 na calibração da vazão diária. Portanto, o desempenho verificado para o método CN foi considerado “Insatisfatório”, de acordo com os critérios estabelecidos por Moriasi et al. (2007); indicando, dessa forma, que essa opção de cálculo do escoamento não é uma alternativa viável para a melhoria da simulação da produção de sedimentos na bacia em questão. Logo, é possível que a não representatividade das produções de sedimentos diárias simuladas esteja mesmo relacionada à limitação do modelo em representar, adequadamente, todos os processos erosivos que ocorrem na bacia, bem como o transporte dos sedimentos à rede de drenagem, especialmente em razão da equação utilizada para cálculo da erosão (MUSLE).

Há que se considerar, igualmente, que o modelo SWAT emprega a distribuição triangular para calcular a chuva máxima diária de 30 min, a qual se relaciona à capacidade de erosão do solo. Contudo, segundo Neitsch et al. (2011), esse método pode resultar em dados

irreais quando utilizado em bacias muito pequenas, o que também pode ter contribuído (em menor proporção) para a não adequabilidade dos processos simulados nessa pesquisa, em todas as escalas de tempo (mensal e diária) e para todas as etapas analisadas (calibração e verificação).

Os menores valores de NS obtidos para a produção de sedimentos podem ainda ser explicados, em parte, pelos resultados da simulação nos meses/anos de estiagem. Nos meses/anos em que não há ou em que existe menor quantidade de precipitação, o modelo SWAT geralmente simula uma pequena produção de sedimentos, o que muitas vezes diverge dos dados observados. Isso ocorre porque o modelo utiliza a MUSLE para cálculo da erosão, que é fortemente dependente das precipitações e de seu potencial erosivo, bem como do escoamento superficial gerado. Esse fator também pode ter sido mais um limitador das simulações da produção de sedimentos.

Buscando minimizar essa questão, foi ativada nessa pesquisa a opção de ocorrência dos processos de degradação/erosão no canal, em conformidade com o reportado por Maier (2013), que identificou a erosão nas margens e no leito do próprio canal como a segunda principal fonte de sedimentos que chegava ao canal em uma sub-bacia da bacia do Taboão. Todavia, ainda assim, os processos erosivos e a produção de sedimentos na bacia não foram bem representados, sobretudo em termos de magnitude dos picos simulados.

Os problemas na determinação da produção de sedimentos também estão, possivelmente, associados aos erros observados na estimativa de parte dos picos mais elevados de vazão, especialmente, em decorrência da dificuldade em representar a variabilidade espacial e temporal das precipitações para alguns dos eventos ocorridos, bem como em função do tipo de escoamento predominante na bacia (subsuperficial). Dessa forma, os erros na determinação de alguns picos de vazões podem ter sido propagados para a estimativa da produção de sedimentos na bacia, reduzindo os picos calculados pelo modelo.

Tal situação poderia ser, parcialmente, minimizada pela introdução de maior número de pluviógrafos dentro da área bacia, a exemplo do demonstrado e sugerido por Depiné (2014), que reportou melhorias na simulação das vazões diárias quando empregados 16 pluviógrafos, decaindo o desempenho das simulações na medida em que menor número de pluviógrafos era utilizado como entrada do modelo SWAT.

Para a melhoria do desempenho das simulações dos processos hidrossedimentológicos pode também ser interessante a introdução de pontos auxiliares de monitoramento da vazão (em sub-bacias da bacia do Taboão), na ocasião da calibração dos processos hidrológicos na bacia,

de maneira a melhorar a representatividade espacial desses processos para as sub-bacias, o que resultaria em melhoria da resposta da bacia como um todo.

De modo geral, nessa pesquisa, o modelo SWAT mostrou-se adequado para as simulações das vazões em escala diária e mensal, com desempenho “Muito Bom” e “Bom” para a calibração e a verificação das vazões mensais, respectivamente e; desempenho “Bom” em ambas as etapas para a escala diária. A produção de sedimentos mensal também foi considerada com “Bom” desempenho na calibração e na verificação, todavia, os maiores picos foram, frequentemente, subestimados pelo modelo; enquanto que as produções mais baixas foram superestimadas. Por outro lado, em termos diários, o desempenho foi considerado “Satisfatório” para a etapa de calibração e “Insatisfatório” na verificação, ocorrendo ainda, grandes limitações na representatividade dos maiores picos da produção de sedimentos no canal, para essa escala de tempo.

É importante salientar, entretanto, que apesar do desempenho “Insatisfatório” observado na etapa de verificação da produção de sedimentos em escala diária, pode-se dizer que as estatísticas observadas nessa pesquisa ainda foram melhores do que aquelas reportadas para a maioria dos estudos realizados no Brasil (descritos na Tabela 10), com emprego do modelo SWAT. Dos 44 estudos descritos nessa tabela, apenas 21 deles realizaram calibração de dados diários de produção de sedimentos e, daqueles que a realizaram, somente três deles resultaram em desempenho “Satisfatório” para o processo de verificação do modelo SWAT (GIBERTONI et al., 2009; PINTO, 2011 e STRAUCH et al., 2013).

Adriolo et al. (2008), por exemplo, ao calibrar e verificar o modelo SWAT para simular a produção e o transporte de sedimentos na bacia do Rio Apucarantina (Paraná), obtiveram um NS de 0,20 e 0,415 na calibração e -2,36 e 0,617 para a verificação, considerando um passo de tempo diário e mensal, respectivamente. Essas estatísticas classificam o modelo como “Insatisfatório” em escala diária (calibração e verificação) e mensal (na calibração).

Já Bonumá et al. (2009, 2010) reportaram “Bom” desempenho do modelo SWAT para a etapa de verificação da produção de sedimentos em uma escala mensal (NS=0,70) na bacia do Arroio Lino (Agudo, Rio Grande do Sul), no entanto, as estatísticas foram “Insatisfatórias” para um passo de tempo diário (NS=-0,33). Os autores utilizaram o período de 1 ano para a calibração e 1 ano para a verificação do modelo.

Gibertoni et al. (2009), por sua vez, descreveram NS igual a 0,41 e 0,524 nas etapas de calibração e de verificação da produção de sedimentos em escala diária, na bacia do rio Nhundiaquara (Baia de Antonina, Paraná), embora tenham reportado desempenho classificado

como “Muito Bom” em um passo de tempo mensal, com $NS=0,936$ na calibração e $NS=0,921$ na verificação. O desempenho na escala diária pode ser considerado “Insatisfatório” na calibração, e “Satisfatório” na verificação.

O mesmo ocorreu com os estudos realizados por Lubitz (2009) e Lubitz, Pinheiro e Kaufmann (2013), ao analisar a produção de sedimentos na bacia do rio Concórdia (Lontras, Santa Catarina). Os autores obtiveram NS igual a $-0,01$ (“Insatisfatório”) para uma escala de tempo diária enquanto que, o desempenho no passo de tempo mensal foi de $0,84$ (“Muito Bom”).

Em pesquisa realizada no rio Apucarantina (Paraná), Santos et al. (2010) descreveram um NS igual a $0,20$ e $-2,36$ na calibração e verificação da produção de sedimentos diária, respectivamente; e um desempenho de $0,42$ e $0,62$ para as etapas de calibração e de verificação, respectivamente, em uma escala mensal.

Schultz, Souza e Santos (2010) obtiveram NS de $0,86$ na simulação da produção de sedimentos mensal na bacia do Altíssimo Rio Negro (Santa Catarina), no entanto, o desempenho foi “Insatisfatório” ($NS=0,38$) para um passo de tempo diário, demonstrando que o modelo SWAT somente poderia ser utilizado para aplicações futuras na bacia para análises da produção mensal.

Da mesma forma, Iensen, Schultz e Santos (2014), ao simular os impactos das mudanças climáticas na dinâmica hidrossedimentológica na bacia do rio Apucarantina (Minas Gerais), obtiveram desempenho considerado “Bom” em um passo de tempo mensal, tanto na calibração ($NS=0,60$) quanto na verificação ($NS=0,70$) do modelo SWAT. Todavia, as estatísticas em uma escala de tempo diária foram classificadas como “Insatisfatórias”, alcançando um NS de apenas $0,38$ na calibração e de $0,47$ na verificação do modelo, respectivamente.

Por outro lado, Pinto et al. (2013) utilizaram o modelo SWAT para simular o escoamento e a concentração de sedimentos suspensos (CSS), em uma escala mensal, na bacia de Lavrinha, na região de Mantiqueira (Minas Gerais). Os autores empregaram 2 anos (setembro de 2006 a agosto de 2008) para a calibração do modelo e 2 anos para a verificação (setembro de 2008 a agosto de 2010). As simulações da CSS resultaram em “Bom” desempenho, com NS igual a $0,68$ e $0,75$ para os períodos de calibração e de verificação, respectivamente.

Resultados reportados por Pinto (2011) também mostraram um “Bom” desempenho do modelo SWAT para a simulação da produção de sedimentos, tanto em uma escala de tempo diária quanto mensal. O autor aplicou o modelo na simulação do escoamento, da produção e do

transporte de sedimentos, além de simulações da qualidade da água; analisando cenários alternativos de uso do solo, com intuito de reduzir a produção e o transporte de sedimentos na bacia de Ribeirão Lavrinhas (Serra da Mantiqueira, Minas Gerais). O NS obtido para a produção de sedimentos foi igual a 0,68 e 0,65 para as etapas de calibração e de verificação, respectivamente, em uma escala diária. Já para a escala de tempo mensal, os valores de NS foram iguais a 0,68 e 0,66 para a calibração e a verificação do modelo, respectivamente.

Frequentemente, a dificuldade em se obter resultados com desempenho “Satisfatório” (ou superior) para a produção de sedimentos, sobretudo em escala diária, tem sido atribuída à falta de dados de monitoramento, à determinação inadequada dos parâmetros necessários à simulação, bem como às deficiências do modelo na representação das complexas relações que interferem nos processos de erosão, transporte e deposição dos sedimentos. Nesse estudo, por exemplo, a não representatividade dos processos, sobretudo quando considerado o passo de tempo diário, pode estar relacionada às rotinas empregadas pelo modelo SWAT para determinação da erosão do solo e também, para cálculo do transporte de sedimentos até a rede de drenagem da bacia; especialmente por haver na bacia do Taboão a presença de algumas voçorocas (não simuladas pelas rotinas usadas no modelo SWAT) e também, pelo escoamento dominante na bacia ser do tipo subsuperficial; o que pode ter contribuído para a ocorrência de limitações mais significativas na representatividade dos processos simulados.

Tais particularidades indicam a necessidade de se testar a aplicação de outras ferramentas para a estimativa da produção de sedimentos na bacia do Taboão, que melhor representem os processos presentes ou ainda, a necessidade de se promover adequações nas rotinas existentes do modelo SWAT, de modo a introduzir esses processos erosivos nas rotinas de cálculo da erosão do solo. A introdução de adequações pode ser interessante, já que esse modelo consegue estimar muito bem os processos hidrológicos na bacia, conforme resultados reportados nessa pesquisa e em estudo realizado por Depiné (2014).

Na Tabela 46 são apresentados os valores médios, medianos, mínimos e máximos da produção de sedimentos anual na bacia do Taboão, para os anos de 2013 a 2015. Os valores simulados pelo modelo variaram entre 0,018 ton/ha no ano de 2013 até 1,684 ton/ha, para o ano de 2015, com produção média no período total de $0,275 \pm 0,306$ ton/ha e mediana de 0,163 ton/ha. Os maiores valores registrados para o ano de 2015 são condizentes com os dados estimados para a produção de sedimentos observada, que também mostraram produções mais elevadas para esse ano em relação aos demais anos analisados, bem como maior erosividade da chuva.

Tabela 46 - Estatísticas da produção de sedimentos anual simulada pelo modelo SWAT para a bacia do Taboão, considerando o período de 2013 a 2015

Estatística	Produção de sedimentos anual (ton/ha)		
	2013	2014	2015
Média *	0,054	0,299	0,473
Desvio padrão *	0,028	0,119	0,427
Mediana *	0,055	0,257	0,513
Mínima *	0,018	0,162	0,022
Máxima *	0,138	0,661	1,684

* As estatísticas da produção de sedimentos anual simulada pelo SWAT foram determinadas tendo por base os valores resultantes da simulação anual dos processos sedimentológicos, considerando, para cada ano, os valores calculados em cada uma das 23 sub-bacias em que a bacia do Taboão foi subdividida.

Fonte: autora

Para uma análise em termos qualitativos, na Figura 47 apresentam-se os resultados da produção anual de água e de sedimentos, por sub-bacia, simulados pelo modelo SWAT para o ano de 2015; considerado o ano de melhor ajuste dos processos sedimentológicos na bacia do Taboão. Esses valores foram calculados a partir da calibração mensal dos processos hidrossedimentológicos.

De forma geral, a distribuição espacial da produção de água e de sedimentos mostrou-se bastante dispersa, com algumas regiões sendo responsáveis pelos valores mais elevados de escoamento superficial e de sedimentos carregados aos cursos d'água. As áreas com maior escoamento superficial e produção de sedimentos ocorreram, comumente, nas regiões onde há elevação do percentual de solos do tipo Nitossolo e Gleissolo (região da saída da bacia- parte inferior à esquerda, e parte superior à esquerda). Esses solos possuem menor capacidade de infiltração da água e também, maior potencial de sofrer processos erosivos, em razão do tipo de estrutura presente. Todos esses fatores, atuando em conjunto, associados ainda, à intensa prática de cultivo agrícola desenvolvido na região, facilitam a ocorrência dos processos erosivos nesses locais. A influência desses fatores sobre os processos erosivos do solo foi apresentada e discutida no item 2.1 da revisão bibliográfica.

Por outro lado, as áreas com menor produção de água e de sedimentos possuem maiores percentuais de solos do tipo Latossolo Vermelho, que possuem melhor estrutura e maior capacidade de infiltração da água sendo, dessa forma, menos susceptíveis à ocorrência dos processos erosivos.

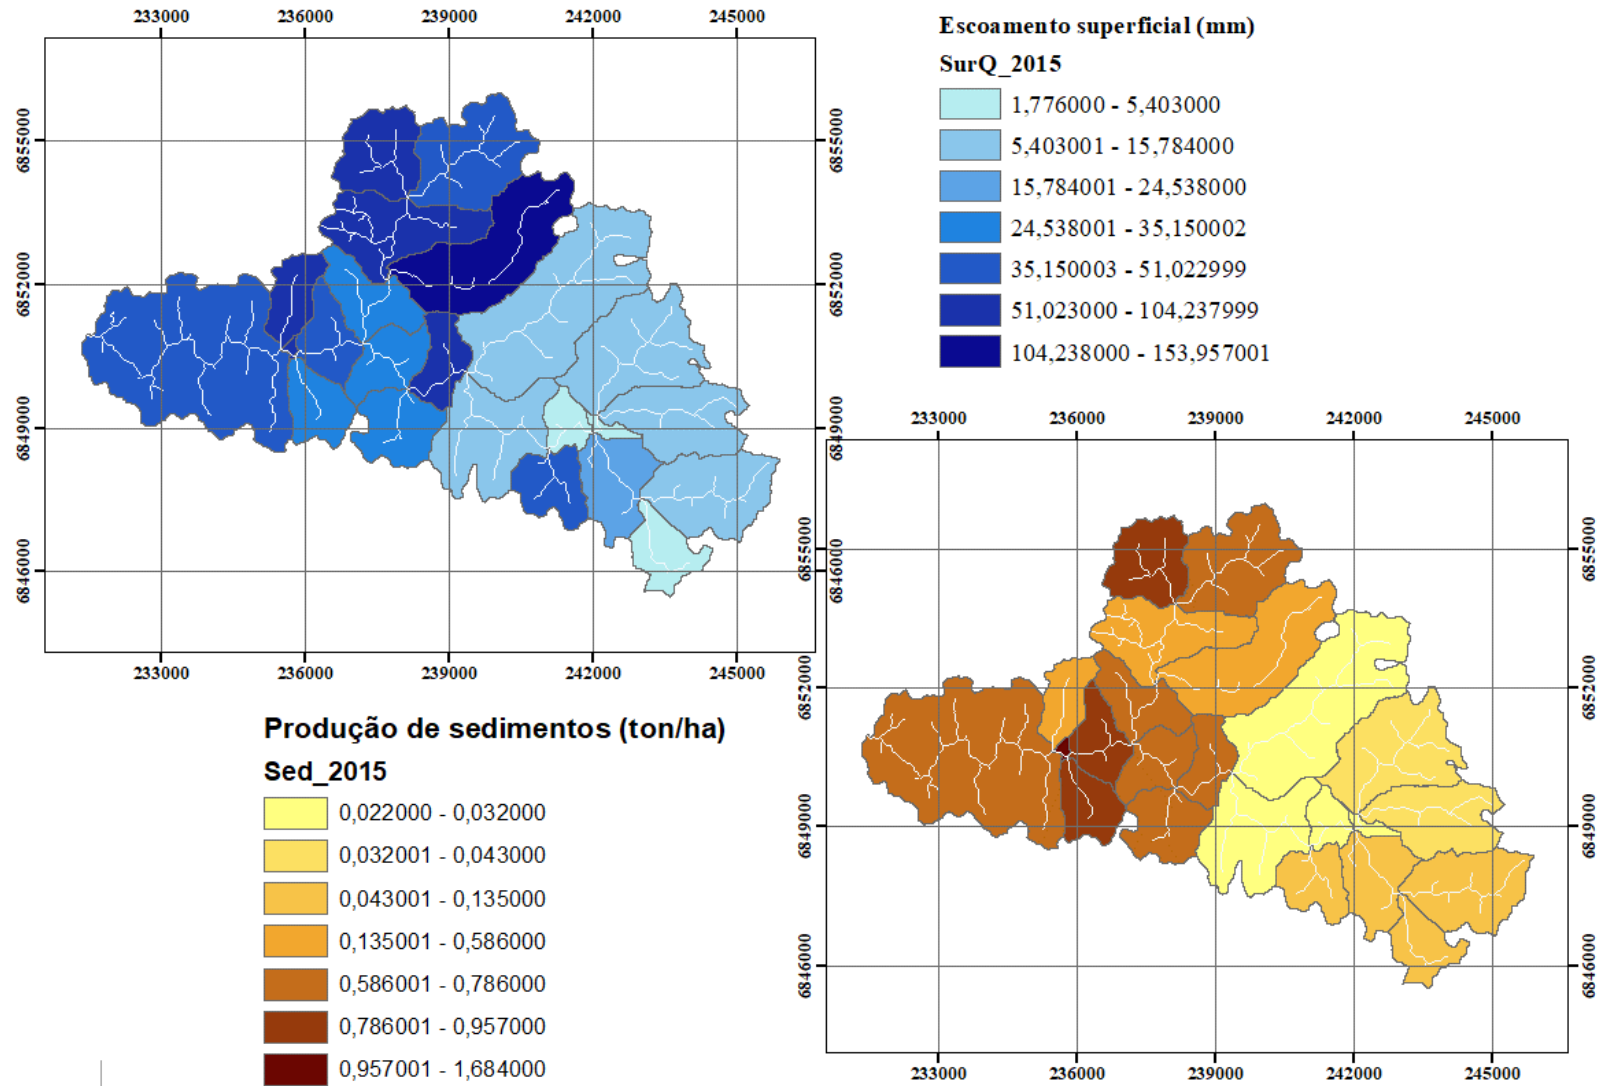
Além disso, nessas regiões identificadas como de maior produção de água e de sedimentos estão localizados diversos pontos classificados como de alto a moderado risco de erosão, conforme estudo e mapeamento realizado por Viero (2004). Na Figura 48 apresenta-se o mapa de risco resultante da pesquisa realizada pela autora. Nessas áreas se desenvolveram, ao longo dos anos, processos fortes a moderados de erosão do solo, até mesmo com surgimento

de voçorocas (indicadas na Figura 48), a maioria das quais já se encontram recuperadas e/ou estabilizadas atualmente.

Os resultados do estudo demonstraram, portanto, que embora a conexão entre a geração, o transporte e a produção de sedimentos seja complexa e, influenciada pela combinação dos diferentes fatores atuantes já citados, bem como pela variação temporal das precipitações e da capacidade de transporte de sedimentos pela rede de drenagem; de modo geral, o modelo SWAT conseguiu delimitar, de forma aproximada, as áreas que possuem maior risco potencial de desenvolvimento dos processos erosivos na bacia, bem como os anos de maior e menor produção. No entanto, a magnitude dos picos da produção de sedimento estimada pelo modelo não é bem determinada, tendo sido observados erros consideráveis nos valores simulados, com subestimativa das produções de sedimentos mais elevadas (período mais úmido) e superestimativa das menores produções (período mais seco).

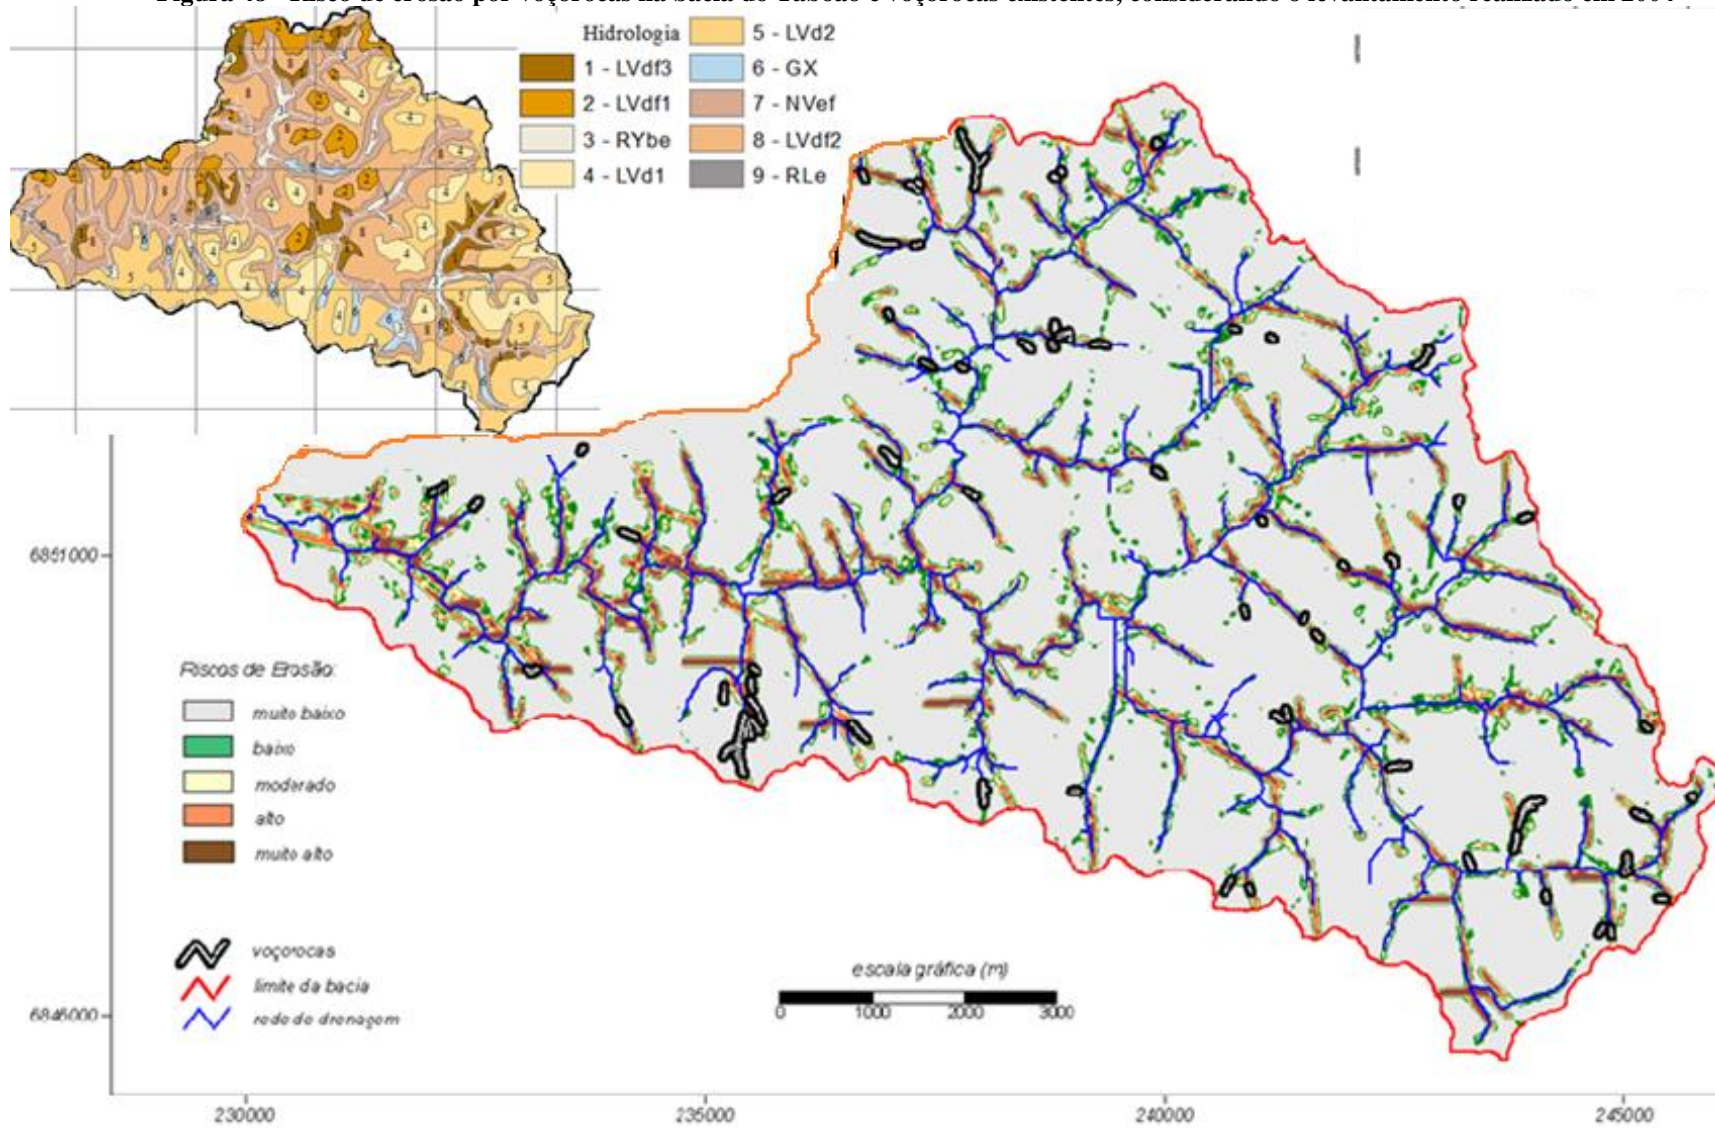
Conforme já destacado, a causa provável dessas limitações deve-se à ocorrência de processos erosivos na bacia do Taboão, que não são simulados pelas rotinas empregadas no modelo SWAT para o cálculo da erosão e do transporte de sedimentos, o que provavelmente contribuiu para o menor aporte de sedimentos ao canal, já que as produções resultantes da erosão nas voçorocas, bem como os sedimentos carregados por esses caminhos preferenciais, não foram simulados. Soma-se a isso a grande quantidade de escoamento subsuperficial que ocorre na bacia o qual, apesar de ser bem simulado pelo modelo SWAT, contribui para a menor produção de sedimentos estimada, uma vez que os processos erosivos no modelo são calculados pela MUSLE, que depende, diretamente, do escoamento superficial ocorrido. Dessa forma, os processos erosivos internos que ocorrem na bacia, possivelmente também não foram bem representados pelas rotinas de cálculo da erosão e da produção de sedimentos empregadas no modelo SWAT, contribuindo para os erros verificados na estimativa das produções de sedimentos.

Figura 47 - Distribuição da produção de água e de sedimentos simuladas pelo modelo SWAT para a bacia do Taboão, considerando o ano de 2015



Fonte: autora

Figura 48 - Risco de erosão por voçorocas na bacia do Taboão e voçorocas existentes, considerando o levantamento realizado em 2004



Fonte: Adaptado de Viero (2004)

5 CONCLUSÕES E RECOMENDAÇÕES

Esse estudo analisou o processo de monitoramento e de modelagem da produção de água e de sedimentos na bacia do Taboão (RS, Brasil), utilizando o modelo SWAT. A produção de sedimentos na bacia foi determinada a partir de informações de vazão (estimadas pela curva-chave) e; por séries contínuas de CSS, calculadas por meio de modelos de RNAs, que empregaram como entrada da rede dados de turbidez e de nível de água.

A metodologia proposta para o treinamento das RNAs para determinação da CSS tem por base um procedimento de pesquisa da complexidade mínima da rede que, sendo progressivamente simplificada a partir de uma rede superdimensionada, que ainda não apresenta redução da capacidade de generalização em relação à rede inicial. O método proposto pode ser aplicado mesmo com poucos registros disponíveis, o que foi uma vantagem em relação aos procedimentos tradicionais, empregados no desenvolvimento de RNAs, que necessitam de uma quantidade maior de dados para treinamento, validação e verificação dos modelos.

Os resultados encontrados demonstraram que é possível estimar a CSS por RNAs, a partir de informações de nível de água e turbidez, com elevada eficiência (NS=0,928 e 0,953 para treinamento e verificação, respectivamente). O desempenho do modelo resultante (Modelo_2) mostrou-se superior àqueles observados quando são utilizadas as relações tradicionais para a estimativa da CSS, com emprego de dados de nível de água (NS=0,581), de turbidez (NS=0,911) ou ainda, de dados conjuntos de turbidez e de nível de água (NS=0,920).

As falhas nos dados de nível de água para determinação da vazão, no período de 2010 a 2016, foram preenchidas por meio de Modelos de Combinações de Redes Neurais Artificiais (CRNAs), com entradas baseadas em informações de precipitação média (estimada pelos dados dos PVGs 34, 40, 43 e 51) e; de dados de nível de água monitorados nas bacias embutidas e/ou adjacente à bacia do Taboão (Donato, Turcato, Alemão e Andorinhas). Das 13 RNAs desenvolvidas para o preenchimento das falhas nos níveis de água no Taboão, apenas uma delas foi classificada como de desempenho “Satisfatório” durante o treinamento e; as demais se enquadraram como de desempenho “Muito Bom”. Para o processo de verificação, sete redes foram consideradas com desempenho “Muito Bom” e cinco com “Bom” desempenho. Tais resultados são indicativos que os modelos de RNAs configuram-se em uma boa alternativa para o preenchimento de dados falhos nos registros de nível de água na bacia do Taboão, quando informações de chuva e de nível de água nas bacias adjacentes estão disponíveis.

Para o preenchimento das falhas nos dados de turbidez, empregados posteriormente nas RNAs para determinação da CSS, foram treinados modelos de RNAs, que tiveram por base informações de nível de água medidos no exutório da bacia do Taboão. No processo de treinamento das RNAs, o desempenho das redes foi classificado como “Bom” para quatro das cinco divisões da amostra total e; como “Muito Bom” para uma das partes da amostra. Tanto na etapa de validação quanto na de verificação, duas das cinco partes da amostra total resultaram em RNAs com desempenho “Muito Bom”, uma delas foi classificada com desempenho “Bom” e; dois dos modelos foram considerados “Satisfatórios”.

A produção de sedimentos na bacia do Taboão, calculada a partir das informações de CSS e de vazão, resultou em 0,66, 1,92 e 2,46 t/ha/ano para os anos de 2013, 2014 e 2015, respectivamente. Os maiores valores e as médias mais elevadas de produção de sedimento, em uma escala de tempo diária e mensal, foram observados para o ano de 2015 e 2014, respectivamente; o que foi condizente com os maiores volumes de chuva registrados para esses anos. O ano de 2013, por outro lado, com totais acumulados de chuva menores, foi o ano que apresentou as produções de sedimentos menores por hectare. O ano de 2015 resultou na produção de sedimentos mais elevada, apesar de possuir menor volume pluviométrico em relação a 2014, o que foi condizente com o maior potencial erosivo observado para as chuvas nesse ano.

Para o preenchimento das falhas nos dados de precipitação horária (entre 2011 e 2016) utilizou-se uma nova metodologia, que empregou modelos de CRNAs, conjugados com o uso de médias (simples - MS ou ponderada pelo inverso da distância - MP). Foram utilizadas como entrada dessas redes, dados de chuva obtidos de pluviógrafos vizinhos ao posto a ser preenchido. O desempenho das RNAs variou de um NS de 0,35 a 0,86, sendo superiores às médias simples (MS) ou às médias ponderadas (MP) em 16 situações das 28 RNAs consideradas. Os modelos de CRNAs associados às médias (CRNA + MS ou CRNA + MP) permitiram o preenchimento dos dados de chuva de cada posto pluviométrico, com eficiência satisfatória, boa ou muito boa em 75% dos casos.

Na simulação dos processos hidrológicos no modelo SWAT, o NS resultante para a calibração e a verificação, em uma escala mensal, foi igual a 0,78 e 0,64, com PBIAS de 6,40% e -5,8% e RSR de 0,47 e 0,60, respectivamente; classificando o modelo como de desempenho “Muito Bom” para o processo de calibração, e “Satisfatório” para a verificação (considerando a estatística NS). Na escala de tempo diária, o modelo SWAT mostrou desempenho maior para a calibração (NS=0,72) e menor para a verificação (NS=0,68), com RSR de 0,53 e 0,56 e;

PBIAS igual a 11,50% e -1,30%, para as etapas de calibração e de verificação, respectivamente; o que classificou o modelo como de desempenho “Bom” para ambas as etapas. Em geral, as vazões simuladas foram inferiores às observadas na etapa de calibração (anos de 2013, 2014 e 2016) e, superiores às observadas no processo de verificação do modelo (anos de 2011 e 2015).

Na simulação da produção de sedimentos mensal na bacia, o modelo SWAT mostrou desempenho considerado “Bom” na calibração (NS=0,66; RSR=0,58 e PBIAS= -15,8%) e na verificação para o critério NS e RSR (NS=0,70; RSR=0,55) e “Muito Bom” para o critério PBIAS= -8,4%). Já na escala diária, o NS resultante da calibração (2013 e 2015) foi igual 0,64, com RSR de 0,60 e PBIAS de -63,00%, enquanto que na etapa de verificação (2014), o NS foi de 0,38, com RSR de 0,79 e PBIAS igual a -35,40%. Essas estatísticas classificaram o modelo como de desempenho “Satisfatório” na calibração e “Insatisfatório” na verificação, considerando o critério NS.

As simulações da vazão e da produção de sedimentos indicaram que, o modelo SWAT possui potencial de utilização em bacias hidrográficas brasileiras. No entanto, nas análises da produção de sedimentos em bacias hidrográficas em que ocorram outros processos erosivos além do tipo do laminar e também, em bacias onde a infiltração da água no solo e o escoamento subsuperficial sejam elevados, podem ser necessárias adequações nas rotinas empregadas no modelo, em especial no referente a determinação dos processos erosivos e do transporte de sedimentos, para que seja possível assegurar melhor representatividade do modelo em relação ao sistema simulado.

São recomendados para estudos futuros:

- 1) Obtenção *in situ* da maior quantidade possível dos parâmetros de entrada necessários para a simulação do modelo SWAT, a fim de garantir a redução da incerteza dos processos de calibração;
- 2) Investir no monitoramento da bacia para assegurar a obtenção de uma série de dados longa, confiável e com menor número de falhas possível, permitindo a extensão das séries utilizadas para calibração e verificação dos processos hidrossedimentológicos na bacia;
- 3) Desenvolver modelos com RNAs para preenchimento dos dados falhos de turbidez, utilizando dados de turbidez e nível de água das bacias vizinhas à bacia do Taboão, defasagens temporais e filtros exponenciais;
- 4) Analisar o desempenho do modelo para a calibração e a verificação dos processos hidrossedimentológicos em períodos seco e úmido, separadamente;

- 5) Calibrar e verificar o modelo utilizando os dados de vazão e de produção de sedimentos monitorados em sub-bacias embutidas à bacia do Taboão (bacias do Donato, Turcato e Alemão), de modo a melhorar a representatividade espacial das simulações e, por consequência, as respostas na saída da bacia do Taboão;
- 6) Introduzir modificações na rotina do modelo, de maneira a estimar a erosão concentrada (sulcos e voçorocas) e o transporte desses sedimentos à rede de drenagem;
- 7) Calibrar e verificar o modelo SWAT com saída (vazão e sedimentos) em diferentes escalas temporais e espaciais;
- 8) Simular cenários de uso e manejo do solo para avaliar as melhores práticas de manejo e os diferentes usos do solo, que podem ser aplicados na bacia do Taboão;
- 9) Testar a aplicação de outros modelos hidrossedimentológicos para a simulação dos processos hidrossedimentológicos na bacia do Taboão.

REFERÊNCIAS

ABBASPOUR, K. C.; YANG, J.; MAXIMOV, I.; SIBER, R.; BOGNER, K.; MIELEITNER, J.; ZOBRIST, J.; SRINIVASAN, R. Modelling of hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. **Journal of Hydrology**, v. 333, n. 2-4, p. 413-430, 2007.

ABBASPOUR, K.C. **SWAT-CUP: SWAT Calibration and Uncertainty Programs- A User Manual**, 2015. 100p.

ABE, T.; MIZUGAKI, S.; TOYABE, T.; MARUYAMA, M.; MURAKAMI, Y.; ISHIYA, T. High Range Turbidity Monitoring in the Mu and Saru River Basins: All-year Monitoring of Hydrology and Suspended Sediment Transport in 2010. **International Journal of Japan Erosion Control Engineering**, v. 5, n. 1, p. 70-79, 2012.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 7181/84: **Solo - Análise granulométrica - procedimento**. Rio de Janeiro: ABNT, 1984. 13p.

ADRIOLO, M.V.; SANTOS, I. dos; GIBERTONI, R.C.; CAMARGO, A.S.G. de. Calibração do modelo SWAT para a produção e transporte de sedimentos. In: VI SIMPÓSIO BRASILEIRO SOBRE PEQUENAS E MÉDIAS CENTRAIS HIDRELÉTRICAS, 18., 2008. **Anais...** Belo Horizonte, MG, 2008.

AFAN, H.A.; EL-SHAFIE, A.; YASEEN, Z.M.; HAMEED, M.M.; MOHTAR, W.H.M.W.; HUSSAIN, A. ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, v. 29, n.4, p. 1231-1245, 2015

AGARWAL, A.; MISHRA, S.K.; RAM, S. SINGH, J.K. Simulation of Runoff and Sediment Yield using Artificial Neural Networks. **Biosystems Engineering**, v. 94, n. 4, p. 597-613, 2006.

AKSOY, H.; KAVVAS, M.L. A review of hillslope and watershed scale erosion and sediment transport models. **Catena**, v. 64, n. 2-3; p. 247-271, 2005.

ALMEIDA, M.S.S.; ALMEIDA, C.R. Análise do desempenho de Redes Neurais Artificiais no preenchimento de falhas em séries de precipitação diária. **Journal of the Brazilian Neural Network Society**, v.10, p. 175-180, 2012.

ALP, M.; CIGIZOGLU, H.K. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. **Environmental Modelling & Software**, v. 22, n. 1, p. 2-13, 2007.

ANCTIL, F.; FILION, M.; TOURNEBIZE, J. A neural network experiment on the simulation of daily nitrate-nitrogen and suspended sediment fluxes from a small agricultural catchment. **Ecological Modelling**, v. 220, n. 22, p. 879-887, 2009.

ANDERSON, C.W. Turbidity. *In*: U.S. GEOLOGICAL SURVEY TECHNIQUES OF WATER-RESOURCES INVESTIGATIONS. **Book 9 - Handbooks for Water-Resources Investigations**, Section A (National Field Manual for the Collection of Water-Quality Data), Chapter A6 (Field measurements), 2005. 55p.

ANDERSON, C.W.; FISK, G.G.; GARTNER, J.W.; GLYSSON, G.D.; GOODING, D.J.; GRAY, J.R.; HORNEWER, N.J.; LARSEN, M.C.; MACY, J.P.; RASMUSSEN, P.P.; WRIGHT, S.A.; ZIEGLER, A.C. Surrogate technologies for monitoring suspended - sediment transport in rivers. *In*: POLETO, C.; CHARLEWORTH, S. (Editors). **Sedimentology of aqueous systems**. Singapore: Willey- Blackwell, ISBN 978-1-4443-3290-2, 2010. p. 1-45.

ANDRADE, M. A.; MELLO, C. R.; BESKOW, S. Simulação hidrológica em uma bacia hidrográfica representativa dos Latossolos na região Alto Rio Grande, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 1, p. 69-76, 2013.

ARAGÃO, R. de; SOARES, M.A.; AMORIM, J.R.A. de; MENDONÇA, L.C.; FIGUEREDO, E.E. de; SRINIVASAN, V.S. Análise de sensibilidade dos parâmetros do modelo SWAT e simulação dos processos hidrossedimentológicos em uma bacia no agreste nordestino. **Revista Brasileira de Ciência do Solo**, v. 37, n. 4, p.1091-1102, 2013.

ARDICLIOGLU, M.; KISI, Ö; HAKTNAIR, T. Suspended sediment prediction using two different feed-forward back-propagation algorithms. **Canadian Journal of Civil Engineering**, v. 34, n. 1, p. 120-125, 2007.

ARNOLD, J.G.; ALLEN, P.M. Automated methods for estimating baseflow and groundwater recharge from streamflow records. **Journal of the American Water Resources Association**, v. 35, n. 2, p. 411- 424, 1999.

ARNOLD, J.G.; ALLEN, P.M.; BERNHARDT, G. A comprehensive surface-groundwater flow model. **Journal of Hydrology**, v. 142, n. 1-4, p. 47-69, 1993.

ARNOLD, J.G.; ALLEN, P.M.; MUTTIAH, R.; BERNHARDT, G. Automated base flow separation and recession analysis techniques. **Ground Water**, v. 33, n. 6, p. 1010-1018, 1995.

ARNOLD, J.G.; MUTTIAH, R.S.; SRINIVASAN, R.; ALLEN, P.M. Regional estimation of base flow and groundwater recharge in Upper Mississippi river basin. **Journal of Hydrology**, v.227, n. 1-4, p.21-40, 2000.

ARNOLD, J.G.; KINIRY, J.R.; SRINIVASAN, R.; WILLIAMS, J.R.; HANEY, E.B.; NEITSCH, S.L. **Soil And Water Assessment Tool - Input/Output Documentation, Version 2012**. Texas Water Resources Institute, TR-439, 2012a. 654p.

ARNOLD, J.G.; MORIASI, D.N.; GASSMAN, P.W.; ABBASPOUR, K.C.; WHITE, M.J.; SRINIVASAN, R.; SANTHI, C.; HARMEL, R.D.; VAN GRIENSVEN, A.; VAN LIEW, M.W.; KANNAN, N.; JHA, M.K. SWAT: model use, calibration, and validation. **Transactions of the ASABE**, v. 55, n. 4, p. 1491-1508, 2012b.

ARROIO JUNIOR, P.P. **Avaliação da produção e transporte de sedimentos na bacia hidrográfica do rio Itaqueri, municípios de Itirapina e Brotas – SP**. 2013. 112f. Dissertação (Mestrado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, da Universidade de São Paulo, São Carlos, 2013.

ARROIO JUNIOR, P.P.; KUWAJIMA, J.S.; MAUAD, F.F. Avaliação da produção de sedimentos em uma bacia de pequeno porte por meio do simulador SWAT. In: XX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 8., 2013. Bento Gonçalves. **Anais...** Bento Gonçalves, RS, ABRH: 2013.

ASANO, S.; SATO, M. Light scattering by randomly oriented spheroidal particles. **Applied Optics**, v. 19, n. 6, p. 962-974, 1980.

ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). Artificial neural networks in hydrology. I: Preliminary concepts. **Journal of Hydrologic Engineering**, v. 5, n. 2, p. 115-123, 2000.

ASTM International. D1889–00 Standard test method for turbidity of water. In: ASTM International. **Annual Book of ASTM Standards, Water and Environmental Technology**, v. 11.01, West Conshohocken, Pennsylvania, 2003. 6 p.

BAGNOLD, R.A. Bedload transport in natural rivers. **Water Resources Research**, v. 13, n. 2, p. 303-312, 1977.

BAKER, E.T., LAVELLE, J.W. The effect of particle size on the light attenuation coefficient of natural suspensions. **Journal of Geophysical Research**, v. 89, p. 8197-8203, 1984.

BALDISSERA, G.C. **Aplicabilidade do modelo de simulação hidrológica SWAT (Soil and Water Assessment Tool), para a bacia hidrográfica do rio Cuiabá/MT**. 2005. 120 f. Dissertação (Mestrado em Física e Meio Ambiente) – Universidade Federal do Mato Grosso, Cuiabá, 2005.

BALTOKOSKI, V. **Modelo SWAT2005 aplicado às sub-bacias dos rios Conrado e Pinheiro – Pato Branco/PR**. 2008. 120f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel, Paraná, 2008.

BARSANTI, P.; DISPERATI, L.; MARRI, P.; MIONE, A. Soil erosion evaluation and multitemporal analysis in two Brazilian basins. In: 2nd INTERNATIONAL SWAT CONFERENCE, 31., Bari. **Proceedings...** Italy. 2003.

BARTEL, G.K.; TERRA, V.S.S.; COLARES, G.L. Estimativa da concentração de sedimentos em suspensão com o uso de sensor ótico de turbidez na bacia do Arroio do Ouro no rio grande do sul. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 13., 2014, João Pessoa, Paraíba. **Anais...** Paraíba: ABRH, 2014. CD-ROM

BASHEER, I.A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and Application. **Journal of Microbiological Methods**, v. 43, n. 1, p. 3-31, 2000.

BAYRAM, A.; KANKAL, M.; ÖNSOY, H. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, v. 184, n. 7, p. 4355-4365, 2012.

BAYRAM, A.; KANKAL, M.; TAYFUR, G.; ÖNSOY, H. Prediction of suspended sediment concentration from water quality variables. **Neural Computing & Applications**, v. 24, n. 5;, p. 1079-1087, 2014.

BLAINSKI, E.; GARBOSSA, L.H.P.; MALUTTA, S. Aplicação do modelo hidrológico SWAT (Soil Water Assessment Tool) para a simulação da perda de solo e da disponibilidade hídrica em uma bacia hidrográfica não instrumentada. In: X SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE, 11., Fortaleza. **Anais...** Fortaleza, Ceará: ABRH, 2010.

BERTONI, J.C.; TUCCI, C.E.M. Precipitação. In: TUCCI, C.E.M. **Hidrologia: Ciência e Aplicação**. 4 ed. 4 reimpressão. Porto Alegre: ABRH/UFRGS, 2012. p. 177-241.

BISANTINO, T.; GENTILE, F.; LIUZZI, G.T. Continuous Monitoring of Suspended Sediment Load in Semi-arid Environments. In: GINSBERG, S.S. (editor). **Sediment transport**, India: InTech, ISBN 978-953-307-189-3, 2011. p. 295-312.

BLACK, K.P.; ROSENBERG, M.A. Suspended sand measurements in a turbulent environment: field comparison of optical and pump sampling techniques. **Coastal Engineering**, v. 24, n. 1-2, p. 137-50, 1994.

BLAINSKI, E.; GARBOSSA, L.H.P.; MALUTTA, S. Aplicação do modelo hidrológico SWAT (Soil and Water Assessment Tool) para a simulação da perda de solo e da disponibilidade hídrica em uma bacia hidrográfica não instrumentada. In: X SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE, 11., 2010, Fortaleza, Ceará. **Anais...**Fortaleza: 2010.

BONAN, G. B. **Ecological Climatology: Concepts and Applications**. Inglaterra: Ed: Cambridge University Press, 2002. 678 p.

BONUMÁ, N.B.; REICHERT, J.M.; MINELLA, J.P.; JACOMET, L.; OLIVEIRA, A. de; RODRIGUES, M.F. Simulação da produção de sedimentos em uma pequena bacia hidrográfica rural no sul do Brasil. In: XXXII CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO, 5., 2009, Fortaleza., Fortaleza, Ceará. **Anais...** Fortaleza, 2009.

BONUMÁ, N.B., REICHERT, J.M., MINELLA, J.P., BARROS, C.A.P., RODRIGUES, M.F., BUARQUE, D.C. Balanço hídrico e sua relação com a modelagem da produção de sedimentos em uma pequena bacia. In: IX ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTO, 17., 2010, Brasília. **Anais...** Brasília, Distrito, 2010.

BONUMÁ, N.B.; REICHERT, J.M.; MINELLA, J.P.; BARROS, C.A.P.; RODRIGUES, M.F.; BUARQUE, D.C. Simulação da vazão e da produção de sedimentos utilizando o modelo SWAT. In: LIMA, J.E.F.W.; LOPES, W.T.A. **Engenharia de Sedimentos: na busca de soluções para problemas de erosão e assoreamento**. Brasília: ABRH, p. 448, 2011.

BONUMÁ, N.B. **Modelagem do escoamento, da produção de sedimentos e da transferência de fósforo em bacia rural no sul do Brasil**. 136 f. 2011. Tese (Doutorado em Ciência do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2011.

BONUMÁ, N.B.; ROSSI, C.G.; ARNOLD, J.G.; REICHERT, J.M.; PAIVA, E.M.C.D. de. Hydrology evaluation of the Soil and Water Assessment Tool considering measurement uncertainty for a small watershed in Southern Brazil. **Applied Engineering in Agriculture**, v. 29, n. 2, p. 189-200, 2013.

BORAH, D.K.; BERA, M. Watershed-scale hydrologic and nonpoint-source Pollution models: review of mathematical bases. **Transactions of the ASAE**, ISSN 0001-2351, v. 46, n. 6, p. 1553-1566, 2003.

_____. Watershed-scale hydrologic and nonpoint-source Pollution models: review of applications. **Transactions of the ASAE**, ISSN 0001-2351, v. 47, n. 3, p. 789-803, 2004.

BORAH, D.K.; YAGOW, G.; SALEH, A.; BARNES, P.L.; ROSENTHAL, W.; KRUG, E.C.; HAUCK, L.M. sediment and nutrient modeling for TMDL development and implementation. **Transactions of the ASABE**, v. 49, n. 4, p. 967-986, 2006.

BORGES, A L. de O, BORDAS, M.P. **Choix de bassins représentatifs et expérimentaux pour l'étude de l'érosion sur le plateau basaltique sudaméricain**. IAHS Publication, v. 174, p. 161-169, 1988.

BOUKHRISSA, Z.A.; KHANCHOUL, K.; BISSONNAIS, Y.L.; TOURKI, M. Prediction of sediment load by sediment rating curve and neural network (ANN) in El Kebir catchment, Algeria. **Journal of Earth System Science**, v. 122, n. 5, p. 1303-1312, 2013.

BOUWER, H. Infiltration of water into nonuniform soil. **Journal Irrigation and Drainage**, ASCE 95, IR4, p. 451-462, 1969.

BRAKENSIEK, D.L. Kinematic flood routing. **Transactions of the ASAE**, v. 10, n. 3, p.340-343, 1967.

BRASIL. Ministerio da Agricultura. Departamento Nacional de Pesquisa Agropecuária. Divisao de Pesquisa Pedologica. **Levantamento de reconhecimento dos solos do estado do Rio Grande do Sul**. Recife: convênio MA/DPP – SA/ DRNR, Boletim Técnico 30, 1973. 431p.

BRASIL, J.B.; SANTOS, J.C.N. dos; PALÁCIO, H.A. de Q.; RIBEIRO FILHO, J.C.; PINHEIRO, A.G. Calibração de turbidímetro para estimativa da concentração de sedimento em suspensão na bacia experimental de Iguatu-CE. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 11, 2014, João Pessoa, Paraíba. **Anais...** João Pessoa: ABRH, 2014. CD-ROM.

BRASINGTON, J.; RICHARDS, K. Turbidity and suspended sediment dynamics in small catchments in the Nepal Middle Hills. **Hydrological Processes**, v.14, n. 14, p. 2559-2574, 2000.

BRESSIANI, D.A.; GASSMAN, P.W.; FERNANDES, J.G.; GARBOSSA, L.; SRINIVASAN, R.; MENDIONDO, E.M.; BONUMA, N.B. A review of SWAT (Soil and Water Assessment Tool) applications in Brazil: challenges and prospects. **International Journal of Agricultural and Biological Engineering (IJABE)**, v. 8, n. 3, p. 9-35, 2015.

BRIGHENTI, T.M. Modelagem hidrológica e avaliação de diferentes métodos de calibração para o modelo SWAT. 2015. 115f. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Federal de Santa Catarina, Florianópolis, 2015.

BRIGHENTI, T.M.; BONUMÁ, N.B.; CHAFFE, P.L.B. Calibração hierárquica do modelo SWAT em uma bacia hidrográfica Catarinense. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 1, p. 53 – 64, 2016.

BRITO, E. **Estimativa da produção de sedimentos da bacia do rio Santa Maria da Vitória – Espírito Santo através do modelo matemático Soil and Water Assessment Tool (SWAT)**. 2015, 84f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal do Espírito Santo, Vitória, 2015.

BROYDEN, C.G. The convergence of a class of double rank minimization algorithms: 2. The new algorithm. **IMA Journal of Applied Mathematics**, v. 6, n. 3, p. 222-231, 1970.

BUNT, J.A.C.; LARCOMBE, P.; JAGO, C.F. Quantifying the response of optical backscatter devices and transmissometers to variations in suspended particulate matter. **Continental Shelf Research**, v. 19, n. 9, p. 1199-1220, 1999.

BUSCHMAN, F.A.; HOITINK, A.J.F.; JONG, S.M. de; HOEKSTRA, P.; HIDAYAT, H.; SASSI, M.G. Suspended sediment load in the tidal zone of an Indonesian river. **Hydrology and Earth System Sciences**, v. 16, n. 11, p. 4191-4204, 2012.

CARDOSO, A.T.; KOBİYAMA, M.; GRISON, F. Problemas na estimativa de sólidos em suspensão associados à elaboração da curva-chave para sensor de turbidez. In: X ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 15, 2012, Foz do Iguaçu, Paraná. **Anais...** Foz do Iguaçu: ABRH, 2012. CD-ROM.

CARVALHO, A.P.; ABRÃO, P.U.R.; FASOLO, P.J.; POTTER, R.J. **Levantamento semidetalhado dos solos da bacia do arroio Taboão (Pejuçara/Ijuí RS)**. Publicação interna, IPH/UFRGS, Porto Alegre, 1990. 41p. + Mapa 1:25.000.

CARVALHO, F.H. de. **Uso do modelo SWAT na estimativa da vazão e da produção de sedimentos em bacia agrícola do Cerrado brasileiro**. 2014. 154f. Dissertação (Mestrado em Agronomia) - Universidade de Brasília, Faculdade de Agronomia e Medicina Veterinária, 2014.

CARVALHO, K.S. de; PARANHOS, R.M.; PAIVA, J.B.D. de. Limitações ao uso da relação entre turbidez e Concentração de sedimento em suspensão em duas pequenas Bacias em Santa

Maria, RS. In: XXI CONGRESSO LATINOAMERICANO DE HIDRÁULICA, 20., 2004, São Pedro, São Paulo. **Anais...** São Paulo: IAHR, 2004. CD-ROM.

CARVALHO, N. de O.; FILIZOLA JÚNIOR, N.P.; SANTOS, P.M.C.; LIMA, J.E.F.W. **Guia de práticas sedimentométricas**. Brasília: ANEEL, 2000. 154p.

CARVALHO, N. de O. **Hidrossedimentologia prática**. 2ª ed., rev., atual e amp. Rio de Janeiro: Interciência, 2008. 599p.

CARVALHO, F.H. de. **Uso do modelo SWAT na estimativa da vazão e da produção de sedimentos em bacia agrícola do cerrado brasileiro**. 2014, 152f. Dissertação (Mestrado em Agronomia) – Universidade de Brasília, Faculdade de Agronomia e Medicina Veterinária, Brasília, 2014.

CARVALHO NETO, J.G. de; SILVA, J.Y.G. da; SILVA, R.M. da; MONTENEGRO, S.M.G.L. Aplicação do modelo SWAT na estimativa de erosão e transporte de sedimentos na bacia do rio Uma. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 18., 2014, João Pessoa, Paraíba. **Anais...** João Pessoa, 2014.

CARVALHO NETO, J.G.; SRINIVASAN, V.S.; RUFINO, I.A.A. Study of hypothetical scenarios in the Riacho dos Namorados Watershed in Cariri Paraibano using SWAT model. **Revista Geográfica Acadêmica**, v. 5, n. 2, p. 30-40, 2011.

CASTRO, K.B. **Avaliação do modelo SWAT na simulação da vazão em bacia agrícola do cerrado intensamente monitorada**. 2013. 141f. Dissertação (Mestrado) – Instituto de Geociências – Universidade de Brasília, Brasília/DF. 2013.

CASTRO, N.M. dos R.; CHEVALLIER, P.; SILVEIRA, A.L.L. da. Agriculture on the Brazilian basaltic plateau. Cultivations practices and soil conservation: first results of the Potiribu project. In: WICHEREK, S. (editor). **Farm Land Erosion: in temperate plains environment and hills**, 1993. p. 403-414.

CASTRO, N.M. dos R.; AUZET, A.-V.; CHEVALLIER, P.; LEPRUN, J.C. Land use change effects on runoff and erosion from plot to catchment scale on the basaltic plateau of Southern Brazil. **Hydrological Processes**, v. 13, p. 1621-1628, 1999.

CASTRO, N.M. dos R. **Ruissellement et érosion sur des bassins versants de grande culture du plateau basaltique du sud du Brésil** (Rio Grande do Sul). 224p. Tese (doutorado em Geografia Física Hidrologia e Geomorfologia) - Université Louis Pasteur, Strasbourg, 1996.

CASTRO, R.A. Simulação de produção de sedimentos com a utilização o modelo swat na bacia do rio das pedras (Guarapuava-PR). **Revista Geonorte**, Edição Especial 4, v. 10, n. 1, p. 297-301, 2014.

CETESB - COMPANHIA DE TECNOLOGIA DE SANEAMENTO AMBIENTAL.
Drenagem Urbana: Manual de Projeto. 2^a ed. São Paulo: CETESB, 1980. 468 p.

CHEVALLIER, P.; CASTRO, N.M. dos R. **As precipitações na região de Cruz Alta e Ijuí (RS-Brasil)**. Recursos Hídricos Publicação, v. 24, 1991. 25p.

CHIKITA, K.A.; WADA, T.; KUDO, I.; KIM, Y. The Intra-Annual Variability of Discharge, Sediment Load and Chemical Flux from the Monitoring: The Yukon River, Alaska. **Journal of Water Resource and Protection**, v. 4, n. 4, p. 173-179, 2012.

CIGIZOGLU, H.K. Estimation and forecasting of daily suspended sediment data by multi-layer perceptrons. **Advances in Water Resources**, v. 27, n. 2, p. 185-195, 2004.

CIGIZOGLU, H.K.; ALP, M. Generalized regression neural network in modelling river sediment yield. **Advances in Engineering Software**, v. 37, n. 2, p. 63-68, 2006.

CIGIZOGLU, H.K.; KISI, O. Methods to improve the neural network performance in suspended sediment estimation. **Journal of Hydrology**, v. 317, n. 3-4, p. 221-238, 2006.

CLIFFORD, N.J.; RICHARDS, K.S.; BROWN, R.A.; LANE, S.N. Laboratory and field assessment of an infrared turbidity probe and its response to particle size and variation in suspended sediment concentration. **Hydrological Sciences Journal**, v. 40, n. 6, p. 771-91, 1995.

COBANER, M.; UNAL, B.; KISI, O. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. **Journal of Hydrology**, v. 367, n. 1-2, p. 52-61, 2009.

CONCEIÇÃO, G.; KOBIYAMA, M.; BELLI FILHO, P.; MIRANDA, C.R. de;
MULLINARI, M. Simulação de vazão e sedimento em bacia hidrográfica rural com alta concentração de suínos e diferentes usos do solo. In: X ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 18., 2012, Foz do Iguaçu. **Anais...** Foz do Iguaçu, Paraná, 2012.

CONNER, C.S.; VISSER, A.M. de. A laboratory investigation of particle size effects on an optical backscatterance sensor. **Marine Geology**, v. 108, p. 151-9, 1992.

DANIEL, E.B.; CAMP, J.V.; LEOEUF, E.J.; PENROD, J.R.; DOBBINS, J.P.; ABKOWITZ, M.A. Watershed Modeling and its Applications: A State-of-the-Art Review. **The Open Hydrology Journal**, v. 5, 26-50, 2011.

DANTAS, J.C.; SILVA, M.A da; SILVA, R.M. da; VIANNA, .C.G. Simulação vazão-erosão usando o modelo SWAT para uma grande bacia da região semiárida da Paraíba. **Geociências**, v. 34, n. 4, p. 816-827, 2015.

DASTORANI, M.T.; MOGHADAMNIA, A.; PIRI, J.; RICO-RAMIREZ, M. Application of ANN and ANFIS models for reconstructing missing flow data. **Environmental Monitoring and Assessment**, v. 166, n. 1-4, p. 421-434, 2010.

DEPINÉ, H. **Influência do preenchimento de falhas de dados horários de precipitação por redes neurais artificiais (RNAs) na simulação hidrológica de base física em uma bacia rural**. 2014. 123f. Tese (Doutorado em Recursos Hídricos e saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014

DEPINÉ, H.; CASTRO, N.M. dos R.; PINHEIRO, A.; PEDROLLO, O. Preenchimento de Falhas de Dados Horários de Precipitação Utilizando Redes Neurais Artificiais. **Revista Brasileira de Recursos Hídricos**, v. 19, n.1, p. 51-63, 2014.

DOUNIA, M., SABRI, D., YASSINE, D. Rainfall–Rain off Modeling Using Artificial Neural Network. **APCBEE Procedia**, v. 10, p. 251-256, 2014.

DOWNING, J., STERNBERG, R.W., LISTER, C.R.B. New instrumentation for investigation of sediment suspension in the shallow marine environment. **Marine Geology**, v. 42, p. 19-34, 1981.

DOWNING, J. Twenty-five years with OBS sensors: The good, the bad, and the ugly. **Continental Shelf Research**, v. 26, p. 2299-2318, 2006.

DURÃES, M.F.; MELLO, C.R.; NAGHETTINI, M. Applicability of the SWAT model for hydrologic simulation in Paraopeba River Basin, MG. **Cerne**, v. 17, n. 4, p. 81-488, 2011.

EDUARDO, E.N.; MELLO, C.R. de; VIOLA, M.R.; OWENS, P.R.; CURI, N. Hydrological simulation subside for management of surface water resources at the Mortes River Basin. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 390-404, 2016.

EDWARDS, T.K.; GLYSSON, G.D. Field Methods for Measurement of Fluvial Sediment. In: U.S. GEOLOGICAL SURVEY. Techniques of Water-Resources Investigations of the U.S. Geological Survey. **Book 3 - Applications of Hydraulics**, 1999, Chapter C2. p.1-89.

EISMA, D. Particle Size of Suspended Matter in Estuaries. **Geo-Marine Letter**, v. 11, p.147-53, 1991.

EISAZADEH, L.; SOKOUTI, R.; HOMAEE, M.; PAZIRA, E. Modeling sediment yield using artificial neural network and multiple linear regression methods. **International Journal of Biosciences**, v. 3, n. 9, p. 116-122, 2013.

EMBRAPA (Empresa Brasileira de pesquisa Agropecuária). Centro Nacional de Pesquisa de Solos (Rio de Janeiro, RJ). **Sistema Brasileiro de Classificação de Solos**. Rio de Janeiro: EMBRAPA-SPI, 1ª edição, 1ª impressão, 1999. 412p.

_____. Centro Nacional de Pesquisa de Solos (Rio de Janeiro, RJ). **Sistema Brasileiro de Classificação de Solos**. Rio de Janeiro: EMBRAPA-SPI, 2ª edição, 1ª impressão, 2006. 306p.

_____. **Manual de métodos de análise de solo**. 2.ed. Rio de Janeiro, 1997. 212p

ESTRANY, J.; GARCIA, C.; BATALLA, R.J. Mediterranean agricultural catchment Suspended sediment transport. **Earth Surface Processes and Landforms**, v. 34, p. 929-940, 2009.

FANTIN-CRUZ, I.; PEDROLLO, O.C.; GIRARD, P.; ZEILHOFER, P.; HAMILTON, S.K. Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. **Journal of hydrology**, v. 399, n. 3-4, p. 376-384, 2011.

FAUSETT, L. **Fundamentals of neural networks**. New Jersey: Prentice-Hall, 1994. 456p.

FERNANDES, J.G.; GALVÍNCIO, J.D.; FREIRE, M.B.G. de S. O Modelo SWAT e suas Possibilidades de Aplicações em APL Agrícolas. **Revista Brasileira de Geografia Física**, v. 01, p. 115-26, 2012.

FERNANDES, J.G. **Estimativa de vazão e produção de sedimentos na bacia hidrográfica do rio São Francisco, utilizando o modelo SWAT**. 2015, 185f. Tese (Doutorado em Geografia) – Universidade Federal de Pernambuco, Recife, 2015.

FERRIGO, S. **Análise de consistência dos parâmetros do modelo SWAT obtidos por calibração automática—estudo de caso da bacia do lago descoberto-DF**. 2014. 147f. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) -Universidade de Brasília, Brasília, 2014.

FERRIGO, S.; MINOTI, R.; KOIDE S. Utilização do modelo SWAT na estimativa de produção de sedimentos decorrentes de diferentes cenários de uso do solo na bacia do córrego Capão Comprido no Distrito Federal. In: XIX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 20., 2011, Maceió, Fortaleza. **Anais...ABRH**: Maceió, 2011.

FERRIGO, S.; TÁVORA, B.E.; MINOTI, R.T.; LIMA, J.E.F.W.; KOIDE, S. Avaliação de possíveis impactos das mudanças climáticas e do uso do solo sobre a produção de sedimentos em bacia hidrográfica no Distrito Federal. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 15., 2014, João Pessoa. **Anais... ABRH**: João Pessoa, 2014.

FEYEREISEN, G.W.; STRICKLAND, T.C.; BOSCH, D.D.; SULLIVAN, D.G. Evaluation of SWAT manual calibration and input parameter sensitivity in the Little River watershed. **Transactions of the American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 843-855, 2007.

FEYZOLAHPOUR, M.; RAJABI, M.; ROOSTAEI, S. Estimating suspended sediment concentration using neural differential evolution (NDE), multilayer perceptron (MLP) and radial basis function (RBF) models. **International Journal of Physical Sciences**, v. 7, n. 29, p. 5106-5117, 2012.

FINLAYSON, B.L. Field calibration of a recording turbidity meter. **Catena**, v. 12, n. 2-3, p. 141-147, 1985.

FLETCHER, R. A new approach to variable metric algorithms. **Computer Journal**, v. 13, p. 317-322, 1970.

FOSTER, I.D.L.; MILLINGTIN, R.; GREW, R.G. The impact of particle size controls on stream turbidity measurement; some implications for suspended sediment yield estimation. **IAHS Publication**, n. 210, p. 51-62, 1992.

FREEMAN, J.A.; SKAPURA, D.M. **Neural networks: algorithms, applications, and programming techniques**. United States of America: Addison-Wesley Publishing Company, Inc., 1991. 401p.

FTS - Forest Technology System DTS-12 SDI Turbidity Sensor: User Manual. 700-DTS-12-Rev, 2013. 27p.

FUKUNAGA, D. C. et al. Application of the SWAT hydrologic model to a tropical watershed at Brazil. **Catena**, v. 125, p. 206-213, 2015.

GAO, P.; JOSEFSON, M. Temporal variations of suspended sediment transport in Oneida Creek watershed, central New York. **Journal of Hydrology**, v. 426-427, p. 17-27, 2012.

GALHARTE, C.A.; VILLELA, J.M.; CRESTANA, S. Estimativa da produção de sedimentos em função da mudança de uso e cobertura do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 2, p. 194-201, 2014.

GARBOSSA, L.H.P.; VASCONCELOS, L.R.C.; LAPA, K.R.; BLAINSKI, E.; PINHEIRO, A. The use and results of the Soil and Water Assessment Tool in Brazil: A review from 1999 until 2010. In: 2011 INTERNATIONAL SWAT CONFERENCE, 27., 2011, Toledo. **Proceedings...** Toledo, Spain, 2011.

GARRIDO, J.M. **Aplicação de modelo matemático de simulação com utilização de SIG à bacia do rio Jiquiriçá – Bahia. Brasília, Distrito Federal, Brasil.** 2003, 198f. Mestrado (Tecnologia Ambiental e Recursos Hídricos) - Universidade de Brasília; Brasília, 2003.

GARTNER, J.W.; GRAY, J.R (editors). Summary of suspended-sediment technologies considered at the Interagency Workshop on Turbidity and Other Sediment Surrogates. In: FEDERAL INTERAGENCY WORKSHOP ON SEDIMENT MONITORING INSTRUMENT AND ANALYSIS RESEARCH, 9., 2003, Flagstaff, Arizona. **Summary**...Arizona: USGS, 2003.

GASSMAN, P.W.; REYES, M.R.; GREEN, C.H.; ARNOLD, J.G. The soil and water assessment tool: historical development, applications, and future research directions. **American Society of Agricultural and Biological Engineers**, v. 50, n. 4, p. 1211-50, 2007.

GHORBANI, M.A.; HOSSEINI, S.H.; FAZELIFARD, M.H.; ABBASI, H. Sediment load estimation by MLR, ANN, NF and Sediment Rating Curve (SRC) in Rio Chama River. **Journal of Civil Engineering and Urbanism**, v. 3, n. 4, p. 136-141, 2013

GIBBS, R.J., WOLANSKI, E. The effects of flocs on optical backscattering measurements of suspended material concentration. **Marine Geology**, v. 107, n. 107, p. 289-91, 1992.

GIBERTONI, R.F.C., SANTOS, I., MÜLLER, I.I., PEREIRA, P.S. Modelagem da produção e transporte de sedimentos em bacias hidrográficas do litoral paranaense: o caso da bacia do rio Nhundiaquara. In XVIII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 18., 2009, Campo Grande, Mato Grosso do Sul. **Anais...** ABRH: Campo Grande, 2009.

GIRARDI, R.V., CASTRO; N.M. de, PINHEIRO, A.; GOLDENFUN, J.A.; SILVEIRA, A.L.L. da. Avaliação do efeito de escala em características de chuva e vazão em sub-bacias embutidas da bacia do Potiribu – RS. **Revista Brasileira de Recursos hídricos**, v. 16, n. 2, p. 49-63, 2011.

GHORBANI, A.M.; HOSSEINI, S.H.; FAZELIFARD, M.H.; ABBASI, H. Sediment load estimation by MLR, ANN, NF and Sediment Rating Curve (SRC) in Rio Chama River. **Journal of Civil Engineering and Urbanism**, v. 3, n. 4, p. 136-141, 2013.

GIROLAMO, A.M.; PAPPAGALLO, G.; PORTO, A.L. Temporal variability of suspended sediment transport and rating curves in a Mediterranean river basin: The Celone (SE Italy). **Catena**, v. 128, p.135-143, 2015.

GOLDFARB, D. A family of variable metric updates derived by variational means. **Mathematics of Computation**, v. 24, n. 109, p. 23-26, 1970.

GONZALES-HIDALGO, J.C.; BATALLA, R.J.; CERDA, A.; LUIS, M. Contribution of the largest events to suspended sediment transport across the USA. **Land Degradation & Development**, v. 21, n. 2, p. 3-91, 2010.

GRAY, J.R.; GLYSSON, G.D. (editors). Proceedings of the Federal Interagency Workshop on Turbidity and Other Sediment Surrogates. In: FEDERAL INTERAGENCY WORKSHOP ON TURBIDITY AND OTHER SEDIMENT SURROGATES, 53., 2002, Reno, Nevada. **US Geological Survey Circular 1250...** Nevada: USGS, 2002.

GRAY, J.R.; PATIÑO, E.; RASMUSSEN, P.P.; LARSEN, M.C.; MELIS, T.S.; TOPPING, D.J.; ALAMO, C.F. Evaluation of sediment surrogate technologies for computation of suspended-sediment transport. In: 1st INTERNATIONAL YELLOW RIVER FORUM ON RIVER BASIN MANAGEMENT, 10., 2003, Reston, VA. **Proceedings...** Reston: U.S. Geological Survey, 2003.

GRAY, J.R.; GARTNER, J.W. Technological advances in suspended-sediment surrogate monitoring. **Water Resources Research**, v. 45, n. 4, p.W00D29, DOI: 10.1029/2008WR007063, 2009.

GREEN, C.H.; VAN GRIENSVEN, A. Autocalibration in hydrologic modeling: Using SWAT2005 in small-scale watersheds. **Environmental Modelling and Software**, v. 23, n. 4, p. 422-434, 2008.

GREEN, M.O.; BOON, J.D. The measurement of constituent concentrations in nonhomogeneous sediment suspensions using optical backscatter sensors. **Marine Geology**, v. 110, n. 1-2, p. 73-81, 1993.

GREEN, W.H.; AMPT, G.A. Studies on soil physics: 1. The flow of air and water through soils. **The Journal of Agricultural Science**, v. 4, n. 1, p. 11-24, 1911.

HADDADCHI, A.; MOVAHEDI, M.; VAHIDI, E.; OMID, M.H.; DEHGHANI, A.A. Evaluation of suspended load transport rate using transport formulas and artificial neural network models (Case study: Chelchay Catchment). **Journal of Hydrodynamics**, v. 25, n. 3, p. 459-470, 2013.

HAIMANN, M.; LIEDERMANN, M.; LALK, P.; HABERSACK, H. An integrated suspended sediment transport monitoring and analysis concept. **International Journal of Sediment Research**, v. 29, n. 2, p.135-148, 2014.

HAMIDI, N.; KAYAALP, N. Estimation of the Amount of Suspended Sediment in the Tigris River using Artificial Neural Networks. **Clean**, v. 36, n. 4, p. 380- 386, 2008.

HARGREAVES, G.L; HARGREAVES, G.H.; RILEY, J.P. Agricultural benefits for Senegal River Basin. **Journal of Irrigation and Drainage Engineering**, v. 111, n. 2, p. 113-124, 1985.

HARRINGTON, S.T.; HARRINGTON, J.R. An assessment of the suspended sediment rating curve approach for load estimation on the Rivers Bandon and Owenabue, Ireland. **Geomorphology**, v. 185, p. 27-38, 2013.

HATCHER, A.; HILL, P.; GRANT, J.; MACPHERSON, P. Spectral optical backscatter of sand in suspension: effects of particle size, composition and colour. **Marine Geology**, v. 168, p. 115-28, 2000.

HAYKIN, S. **Neural networks**: a comprehensive foundation. India: Pearson Education, Second edition, 2001. 823p.

HECHT-NIELSEN, R. **Neurocomputing**. Boston: Addison-Wesely Publishing Company, 1990. 433p.

HILLEL, D. **Introduction to Soil Physics**. San Diego, CA: Academic Press Inc., 1982. 392p

HORNIK, K.; STINCHCOMBE, M; WHITE, H. Multilayer Feedforward Networks are Universal Approximators. **Neural Networks**, v. 2, n. 5, p. 359-66, 1989.

HU, Y.H.; HWANG, J.-N. **Handbook of neural network signal processing**. United States of America: CRC Press LLC, 2002. 384p.

HUDSON, R. **Interpreting Turbidity and Suspended-Sediment Measurements in High-Energy Streams in Coastal British Columbia**. Forest Research Technical Report TR-008, Research Section, Vancouver Forest Region, BCMOF, 2001. 16p.

HUDSON-EDWARDS, K. Fluvial environments. In: PERRY, C. e TAYLOR, K. (Org.). **Environmental sedimentology**. Blackwell Publishing, 2007. p. 75-108.

IENSEN, I.R.R.; SCHULTZ, G.B.; SANTOS, I. Simulation of hydrosedimentological impacts caused by climate change in the Apucarantina River watershed, southern Brazil. **IAHS Publication**, 367, p. 363-373, 2014.

IBGE (Instituto Brasileiro de Geografia e Estatística). Coordenação de Recursos Naturais e Estudos Ambientais. **Manual Técnico de Uso da Terra**. Manuais Técnicos em Geociências, número 7, 3. ed. Rio de Janeiro: IBGE, 2013. 171p.

IPAGRO. **Atlas agroclimático do Estado do Rio Grande do Sul**. Porto Alegre: IPAGRO, v. 3, mapa n. 232, 1989.

JAIN, S.K. Development of integrated sediment rating curves using ANNs. **Journal of Hydraulic Engineering**, v. 127, n. 1, p. 30-37, 2001.

_____ Development of Integrated Discharge and Sediment Rating Relation Using a Compound Neural Network. **Journal of Hydraulic Engineering**, v.13, n. 3, p. 124-131, 2008.

JOTHIPRAKASH, V.; GARG, V. Reservoir Sedimentation Estimation Using Artificial Neural Network. **Journal of Hydrologic Engineering**, v. 14, n. 9, p. 1035-1040, 2009.

KANNAN, N.; WHITE, S.M.; WORRALL, F.; WHELAN, M.J. Sensitivity analysis and identification of the best evapotranspiration and runoff options for hydrological modeling in SWAT-2000. **Journal of Hydrology**, v. 332, n. 3-4, p. 456-466, 2007.

KASABOV, N. **Foundations of neural networks, fuzzy systems and knowledge engineering**. Cambridge: Massachusetts institute of technology, 1998. 550p.

KASHANI, M.H.; DINPASHOH, Y. Evaluation of efficiency of different estimation methods for missing climatological data. **Stochastic Environmental Research and Risk Assessment**, v. 26, n. 1, p. 59-71, 2012

KAZEMZADEH, M.B.; AYYOUBZADEH, S.A.; MORIDNEZHAD, A. Remote Sensing of Temporal and Spatial Variations of Suspended Sediment Concentration in Bahmanshir Estuary, Iran. **Indian Journal of Science and Technology**, v. 6, n. 8, p. 5036-5045, 2013.

KIM, S.E.; SEO, I.W. Artificial Neural Network ensemble modeling with conjunctive data clustering for water quality prediction in rivers. **Journal of Hydro-environment Research**, v. 9, p. 325-339, 2015.

KINEKE, G.C.; STERNBERG, R.W. Measurements of high concentration suspended sediments using the optical backscatterance sensor. **Marine Geology**, v. 108, n. 3-4, p. 253-58, 1992.

KISI, O. Constructing neural network sediment estimation models using a data-driven algorithm. **Mathematics and Computers in Simulation**, v. 79, n. 1, p. 94-103, 2008.

_____. Development of Streamflow-Suspended Sediment Rating Curve Using a Range Dependent Neural Network. **International Journal of Science & Technology**, v. 2, n. 1, p. 49-61, 2007.

_____. Modeling discharge-suspended sediment relationship using least square support vector machine. **Journal of Hydrology**, v. 456-457, p. 110-120, 2012.

_____. Multi-layer perceptrons with Levenberg–Marquardt optimization algorithm for suspended sediment concentration prediction and estimation. **Hydrological Science Journal**, v. 49, n. 6, p. 1025-1040, 2004.

_____. Suspended sediment estimation using neuro-fuzzy and neural network approaches. **Hydrological Sciences Journal**, v. 50, n. 4, p. 683-696, 2005.

KISI, O.; HAKTANIR, T.; ARDICLIOGLU, M.; OZTURK, O.; YALCIN, E.; ULUDAG, S. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. **Advances in Engineering Software**, v. 40, n. 6, p. 438-444, 2009.

KISI, O.; OZKAN, C.; AKAY, B. Modeling discharge–sediment relationship using neural networks with artificial bee colony algorithm. **Journal of Hydrology**, v. 428-429, p. 94-103, 2012.

KISI, O.; SHIRI, J. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. **Computers & Geosciences**, v. 43, n. 3-4, p. 73-82, 2012.

KISI, O.; DAILR, O.H.; CIMEN, M.; SHIRI, J. Suspended sediment modeling using genetic programming and soft computing techniques. **Journal of Hydrology**, v. 450-451, p. 48-58, 2012.

KLEIZEN, H.H.; PUTTER, A.B. de; BEEK M.V.D.; HUYNINK, S.J. Particle concentration, size and turbidity. Based on a presentation at the Filtech Europa 93 Conference in Karlsruhe, Germany on 19 October 1993, revised and expanded May 1995. **Filtration & Separation**, p. 897-901, 1995.

KRÖSE, B.; SMAGT, P.V.D. **An introduction to Neural Networks**. University of Amsterdam. Eighth edition, 1996. 135p.

KUHNLE, R.A.; WREN, D.G. Breakout Session I, Suspended-Sediment Measurement: Data Needs, Uncertainty, and New Technologies. In: GRAY, J.R. (editor). FEDERAL INTERAGENCY SEDIMENT MONITORING INSTRUMENT AND ANALYSIS RESEARCH WORKSHOP, 4., 2003, Flagstaff, Arizona. **Proceedings... Arizona: U.S. Geological Survey Circular 1276**, 2003. Disponível em: <http://water.usgs.gov/osw/techniques/sediment/sedsurrogate2003workshop/listofpapers.html>. Acessado em: dezembro 2014.

KUWAJIMA, J.I. **Análise do modelo SWAT como ferramenta de prevenção e de estimativa de assoreamento no reservatório do lobo (Itirapina/Brotas/SP)**. 2012, 158f. Dissertação (Mestrado em Engenharia Ambiental) - Escola de Engenharia de São Carlos, da Universidade de São Paulo, São Carlos, 2012.

KUMAR, A.R.; OJHA, C.S.P.; GOYAL, M.K.; SINGH, R.D.; SWAMEE, P.K. Modeling of Suspended Sediment Concentration at Kasol in India Using ANN, Fuzzy Logic, and Decision Tree Algorithms. **Journal of Hydrologic Engineering**, v. 17, n. 3, p. 394-404, 2012.

LAFDANI, E.K.; NIA, A.M.; AHMADI, A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. **Journal of Hydrology**, v. 478, p. 50-62, 2013

LATIMER, P. Light scattering by a homogeneous sphere with radial projections. **Applied Optics**, v. 23, n. 3, p. 442-47, 1984.

LEE, J.-W.; PARK, S.-C. Artificial Neural Network-Based Data Recovery System for the Time Series of Tide Stations. **Journal of Coastal Research**, v. 32, n. 1, p: 213-224, 2016.

LEFRANCOIS, J.; GRIMALDI, C.; GASCUEL-ODOUX, C.; GILLIET, N. Suspended sediment and discharge relationships to identify bank degradation as a main sediment source on small agricultural catchments. **Hydrological Processes**, v. 21, n. 21, p. 2923-2933, 2007.

LELIS, T.A.; CALIJURI, M.L. Modelagem hidrossedimentológica de bacia hidrográfica na região sudeste do Brasil, utilizando o SWAT. **Revista Ambiente & Água**, v. 5, n. 2, p. 158-174, 2010.

LELIS, T.A.; CALIJURI, M.L.; SANTIAGO, A. da F.; LIMA, D.C. de; ROCHA, E. de O. Análise de Sensibilidade e Calibração do Modelo Swat Aplicado em Bacia Hidrográfica da Região Sudeste do Brasil. **Revista Brasileira de Ciências do Solo**, v. 36, n. 2, p. 623-634, 2012.

LENHART, T.; ECKHARDT, K.; FOHER, N.; FREDE, G.-G. Comparison of two different approaches of sensitivity analysis. **Physics and Chemistry of the Earth**, v. 27, p. 645-654, 2002.

LENZI, M.A.; MARCHI, L. Suspended sediment load during floods in a small stream of the Dolomites northeastern Italy. **Catena**, v. 39, n. 4, p. 267-82, 2000.

LESSA, L.G.F. **Simulação da produção de sedimentos na bacia hidrográfica do Rio Pardo – Botucatu/SP, por modelagem hidrológica**. 2011, 141f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônômicas da UNESP, Botucatu, 2011.

LEWIS, J. Turbidity-controlled suspended sediment sampling for runoff-event load estimation. **Water Resources Research**, v. 32, n. 7, p. 2299-2310, 1996.

_____ Estimation of suspended sediment flux in streams using continuous turbidity and flow data coupled with laboratory concentrations. In: FEDERAL INTERAGENCY WORKSHOP ON TURBIDITY AND OTHER SEDIMENT SURROGATES, 3., 2002, Reno, NV. **Proceedings...** Reno: U.S. Geological Survey Circular 1250, 2002. Disponível em: <http://water.usgs.gov/osw/techniques/TSS/listofabstracts.htm>. Acessado em: dezembro 2014.

_____ Turbidity-controlled sampling for suspended sediment load estimation. **IAHS Publication**, n. 283, p. 13-20, 2003.

LEWIS, J.; EADS, R. **Implementation Guide for Turbidity Threshold Sampling: Principles, Procedures, and Analysis** Jack Lewis and Rand Eads. General Technical Report, PSW-GTR-212, March 2009. 87p.

LIETZ, A.C.; DEBIAK, E.A. **Development of Rating Curve Estimators for Suspended-Sediment Concentration and Transport in the C-51 Canal Based on Surrogate Technology, Palm Beach County, Florida, 2004-05**. U.S. Geological Survey Open-File Report 2005-1394, 2005. 19 p.

LINO, J.F.L.; CORSEUIL, C.W.; KOBİYAMA, M.; MALUTTA, S.; UDA, K.; BORTOLOTTI, N.L.; SANTOS, I. dos. Análise da vazão da bacia hidrográfica do rio Preto com o modelo SWAT. In: XVIII Simpósio Brasileiro de Recursos Hídricos, 20., Campo Grande. **Anais...** Campo Grande, Mato Grosso do Sul: ABRH, 2009.

LINO, J.F. L. **Análise da dinâmica hidrossedimentológica da bacia hidrográfica do rio preto (SC) com o modelo SWAT**. 2009, 150f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2009.

LIU, Q.-J.; SHI, Z.-H.; FANG, N.-F.; ZHU, H.D.; AI, L. Modeling the daily suspended sediment concentration in a hyperconcentrated river on the Loess Plateau, China, using the Wavelet-ANN approach. **Geomorphology**, v. 186, p. 181-190, 2013.

LOITZENBAUER, E.W.; ADAM, K. N. Análise Espacial da Precipitação Média Mensal na Sub-Bacia do Taboão (RS), Durante os Anos de 2001 a 2008. In: XIX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 2011, Maceió, Alagoas. **Anais...** Maceió: ABRH, 2011.

LONDHE, S.; DIXIT, P.; SHAH, S.; NARKHEDE, S. Infilling of missing daily rainfall records using artificial neural network. **ISH Journal of Hydraulic Engineering**, v. 21, n. 3, p. 255-24, 2015

LOPES, G.R.; TÁVORA, B.E.; SANTOS, R.M. dos; KOIDE, S. Estudo sobre correlação entre turbidez e sólidos em suspensão para estimativa da vazão sólida em uma pequena bacia. In: XVIII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 13., 2009, Campo Grande, Mato Grosso do Sul. **Anais...** Campo Grande: ABRH, 2009.

LOPES, P. M. O.; VALERIANO, D. M. Validação do albedo da superfície terrestre obtido dos dados do sensor MODIS em regiões montanhosas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 2007. Florianópolis. **Anais...** . Florianópolis: INPE, 2007.

LOPES, N.H.Y. **Análise da produção de água e sedimentos em microbacias experimentais com o modelo SWAT**. 2008, 154f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2008.

LOPES, N.H.Y.; KOBAYAMA, M. Análise da produção de sedimentos e da qualidade da água em uma microbacia experimental com SWAT. In: VIII Encontro Nacional de Engenharia de Sedimentos, 10., 2008, Campo Grande, Mato Grosso do Sul. **Anais...** Campo Grande, 2008.

LUBITZ, E. Avaliação da aplicação do modelo hidrológico SWAT à bacia do ribeirão concórdia – Lontras, SC. 2009, 111f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Regional de Blumenau, Blumenau, 2009.

LUBITZ, E.; PINHEIRO, A.; KAUFMANN, V. Simulação do Transporte de Sedimentos, Nitrogênio e Fósforo na Bacia do Ribeirão Concórdia, SC. **Revista Brasileira de Recursos Hídricos**, v. 18, n .2, p. 39-54, 2013.

LUCIO, P.S.; CONDE, F.C.; CAVALCANTI, I.F.A.; SERRANO, A.I.; RAMOS, A. M.; CARDOSO, A.O. Spatiotemporal monthly rainfall reconstruction via artificial neural network (case study: South Brazil). **Journal of Advances in Geosciences**, v. 10, p. 67-76, 2007.

LUDWIG, K.A.; HANES, D.M. A laboratory evaluation of optical backscatterance suspended solids sensors exposed to sand-mud mixtures. **Marine Geology**, v. 94, n. 1-2, p. 173-79, 1990.

MAA, J., XU, J. Notes on the performance of an optical backscatter sensor for cohesive sediment. **Marine Geology**, v. 104, n. 1-4, p. 215-18, 1992.

MACDONALD, J.S.; BEAUDRY, P.G.; MACISAAC, E.A.; HERUNTER, H.E. The effects of forest harvesting and best management practices on streamflow and suspended sediment concentrations during snowmelt in headwater streams in sub-boreal forests of British Columbia, Canada. **Canadian Journal of Forest Research**, v. 33, n. 8, p. 1397-1407, 2003.

MACHADO, R.E. **Simulação de escoamento e de produção de sedimentos em uma microbacia hidrográfica utilizando técnicas de modelagem e geoprocessamento**. 2002, 152f. Tese (Mestrado em Agronomia) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2002.

MACHADO, R.E.; VETTORAZZI, C.A. Simulação da produção de sedimentos para a microbacia hidrográfica do Ribeirão dos Marins (SP). **Revista Brasileira de Ciências do Solo**, v. 27, n. 4, p. 735-741, 2003.

MACHADO, R.E.; VETTORAZZI, C.A. XAVIER, A.C. Simulação de cenários alternativos de uso da terra em uma microbacia utilizando técnicas de modelagem e geoprocessamento. **Revista Brasileira de Ciências do Solo**, v. 27, n. 4, p. 727-733, 2003.

MACHADO, R.E.; XAVIER, A.C.; VETTORAZZI, C.A. Efeito do Nível de Subdivisão em uma Bacia Hidrográfica na Simulação da Produção de Sedimentos. **Revista Brasileira de Recursos Hídricos**, v. 12, n.4, p. 49-58, 2007.

MAIER, C. **Variabilidade intra-evento da origem das fontes de sedimentos em uma bacia hidrográfica rural**. 2013. 124f. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

MALUTTA, S. **Estudo hidrossedimentológico da bacia hidrográfica do Rio Negrinho - SC com o modelo SWAT**. 2012, 126f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2012.

MANO V.; NEMERY, J.; BELLEUDY, B.; POIREL, A. Assessment of suspended sediment transport in four alpine watersheds (France): influence of the climatic regime. **Hydrological Processes**, v. 23, n. 5, p. 777-92, 2009.

MANZ, R.E.; SANTOS, I. DOS; PAULA, E.V. de. Monitoramento automático do transporte de sedimento em suspensão por meio de turbidímetro de alta performance. In: IX ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 14., 2010, Brasília, Distrito Federal. **Anais...** Brasília: ABRH, 2010.

MARCHIORO, E.; FERNANDES, N.F.; MACEDO, J.R. de; BHERING, S.B.; GONÇALVES, S.B.; ORTEGA, A., CAIADO, M.A.C. Modelagem da produção de sedimentos no noroeste fluminense como subsídio ao planejamento ambiental: um estudo de caso da bacia do córrego Santa Maria. **Revista Brasileira de Geomorfologia**, v. 12, n. 1, p. 29-38, 2011.

MARCHIORO, E. **Modelagem hidrossedimentológica na bacia do córrego Santa Maria: Subsídios à aplicação de práticas de conservação de água e solo no noroeste fluminense**. 2008. 189f. Tese (Doutorado em geografia) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

MARCHIORO, E.; FERNANDES, N.F.; MACEDO, J.R. de; BHERING, S.B.; GONÇALVES, S.B.; PRADO, R.B. Modelagem da produção de sedimentos usando cenário ambiental alternativo no noroeste do Rio de Janeiro – Brasil. **Geografias**, v.10, n. 1, p. 54-70, 2014.

MARTTILA, H.; KLOVE, B. Use of Turbidity Measurements to Estimate Suspended Solids and Nutrient Loads from Peatland Forestry Drainage. **Journal of Irrigation and Drainage Engineering**, v. 138, n. 12, p. 1088-96, 2012.

MATZENAUER, R.; RADIN, B.; ALMEIDA, I.R. de (editors). **Atlas Climático: Rio Grande do Sul**. Porto Alegre: Secretaria da Agricultura Pecuária e Agronegócio, Fundação Estadual de Pesquisa Agropecuária (FEPAGRO), 2011.

MEDEIROS, J.D.F. **Variabilidade espacial do conteúdo de água no solo na bacia do Arroio Donato-RS**. 139p. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

MEDEIROS, I.C. de; SILVA, R.M. da. Análise da erosão hídrica na região semiárida da Paraíba usando o modelo SWAT acoplado a um sig. **Geociências**, v. 33, n. 3, p.457-471, 2014.

MENDIONDO, E. M.; CASTRO, N. M. dos R.; AUZET, A. V.; CHEVALLIER, P. Surface flow pathways in subtropical agricultural headwaters: a case study from southern Brazil. In: INTERNATIONAL CONFERENCE ON HEADWATER CONTROL, 4, Merano-Italy, 1998. **Headwaters: water resources and soil conservation**. Merano: IAHC/WASWC, 1998a. p.285-292.

MEGNOUNIF, A.; TERFOUS, A.; OUILLOU, S. A graphical method to study suspended sediment dynamics during flood events in the WadiSebdou, NW Algeria (1973–2004). **Journal of Hydrology**, v. 497, p. 24-36, 2013.

MEIN, R.G.; LARSON, C.L. Modeling infiltration during a steady rain. **Water Resources Research**, v. 9, n. 2, p. 384-394, 1973

MEIRA NETO, A.A.; FONTES, A.S.; MEDEIROS, Y.D.P. Aplicabilidade do modelo SWAT a um sistema hidrológico complexo de clima semi-árido. In: XIX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, Maceió. **Anais...** Maceió, Alagoas: ABRH, 2011.

MELESSE, A.M.; AHMAD, S.; MCCLAINA, M.E.; WANG, X.; LIM, Y.H. Suspended sediment load prediction of river systems: An artificial neural network approach. **Agricultural Water Management**, v. 98, n. 5, p. 855-866, 2011.

MELLO, N. A. de. Relação entre a fração mineral do solo e qualidade de sedimento - o solo como fonte de sedimentos. In: POLETO, C. e MERTEN, G. H. (org.). **Qualidade dos sedimentos**. Porto Alegre: ABRH, 2006. p. 38-82.

MELO NETO, J.O.; SILVA, A.M. da; MELLO, C.R. de; MELLO JUNIOR, A.V. Simulação hidrológica escalar com o modelo SWAT. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 1, p.177-188, 2014.

MEMARIAN, H.; BALASUNDRAM, S.K. Comparison between Multi-Layer Perceptron and Radial Basis Function Networks for Sediment Load Estimation in a Tropical Watershed. **Journal of Water Resource and Protection**, v. 4, n. 10, p. 870-876, 2012,

MERRITT, W.S.; LETCHER, R.A.; JAKEMAN, A.J. A review of erosion and sediment transport models. **Environmental Modelling & Software**, v. 18, n. 8-9, p. 761-799, 2003.

MERTEN, G.H.; CAPEL, P.D.; MINELLA, J.P.G. Effects of suspended sediment concentration and grain size on three optical turbidity sensors. **Journal of Soils and Sediments**, v. 14, n. 7, p. 1235-1241, 2014.

MINELLA, J.P.G.; MERTEN, G.H.; REICHERT, J.M.; CLARKE, R. Estimating suspended sediment concentrations from turbidity measurements and the calibration problem. **Hydrological Processes**, v. 22, n. 12, p. 1819-30, 2008.

MINOTI, R.T. **Abordagens Qualitativa e Quantitativa de Microbacias Hidrográficas e Áreas Alagáveis de um Compartimento do Médio Mogi-Superior-SP**. 2006, 231f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2006.

MIRANDA, E.E. de (Coord.). **Brasil em Relevô**. Campinas: Embrapa Monitoramento por Satélite, 2005. Disponível em: <<http://www.relevobr.cnpm.embrapa.br>>. Acesso em: 8 abr. 2014.

MOHAMMED, S.; MOLLAH, H. Development of a sequential Artificial Neural Network for predicting river water levels based on Brahmaputra and Ganges water levels. **Neural Computing and Applications**, v. 26, n. 8, p.1979-1990, 2015.

MONTEITH, J.L. Evaporation and the environment in the state and movement of water in living organisms. In: 19 SYMPOSIA OF THE SOCIETY FOR EXPERIMENTAL BIOLOGY, 43., 1965, Universidade de Cambridge. **Proceedings...** Londres: Press, p.205-234. 1965.

MOORE, R.J. **Real-time forecasting of flood events using transfer function noise models: Report, Part 2.** Wallingford, Institute of Hydrology, 1980. 155p.

MORGAN, R.P.C. **Soil erosion & conservation.** United Kingdom: Blackwell Publishing Ltd. 3rd ed., 2005. 304p.

MORIASI, D.N.; ARNOLD, J.G.; VAN LIEW, M.W.; BINGNER, R. L.; HARMEL, R.D.; VEITH, T.L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the American Society of Agricultural and Biological Engineers**, v. 50, n. 3, p. 885-900, 2007.

MORO, M. **A utilização da interface SWAT-SIG no estudo da produção de sedimentos e do volume de escoamento superficial com simulação de cenários alternativos.** 2005, 100f. Dissertação (Mestrado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2005.

MOUNT, N.J.; ABRAHART, R.J. Load or concentration, logged or unlogged? Addressing ten years of uncertainty in neural network suspended sediment prediction. **Hydrological Processes**, v. 25, n. 20, p. 3144-3157, 2011.

MUHAMMADI, A.; AKBARI, G.; AZIZZIAN, G. Suspended sediment concentration estimation using artificial neural networks and neural-fuzzy inference system case study: Karaj Dam. **Indian Journal of Science and Technology**, v. 5, n. 8, p. 3188- 3193, 2012.

MUSTAFA, M.R.; ISA, M.H.; REZAUR, R.B. A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River- A Case Study in Malaysia. **International Journal of Environmental, Earth Science and Engineering**, v. 5, n. 9, p. 46-50, 2011.

MUSTAFA, M.R.; REZAUR, R.B.; SAIEDI, S.; ISA, M.H. River Suspended Sediment Prediction Using Various Multilayer Perceptron Neural Network Training Algorithms - A Case Study in Malaysia. **Water Resources Management**, v. 26, n. 7, p.1879-1897, 2012.

MWALE, F.D.; ADELOYE, A.J.; RUSTUM, R. Infilling of missing rainfall and streamflow data in the Shire River basin, Malawi—a self organizing map approach. **Physics and Chemistry of the Earth**, v. 50-52, p. 34–43, 2012.

NAJAH, A.; EL-SHAFIE, A.; KARIM, O.A.; EL-SHAFIE, A.H. Application of artificial neural networks for water quality prediction. **Neural Computation & Application**, v. 22 (Suppl 1), p. 187-201, 2013.

NASH, J.E.; SUTCLIFFE, J.V. River flow forecasting through conceptual models part I - A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282-290, 1970.

NAVRATIL, O.; ESTEVES, M.; LEGOUT, C.; GRATIOT, N.; NEMERY, J.; WILLMORE, S.; GRANGEON, T. Global uncertainty analysis of suspended sediment monitoring using turbidimeter in a small mountainous river catchment. **Journal of Hydrology**, v.398, n. 3-4, p. 246-59, 2011.

NEARING, M.A.; LIU, B.Y.; RISSE, L.M.; ZHANG, X. Curve number and Green-Ampt effective hydraulic conductivities. **Water Resources Bulletin**, v. 32, n.1, p.125-136, 1996.

NEITSCH, S.L. ARNOLD, J.G. KINIRY, J.R. WILLIAMS, J.R. SRINIVASAN, R. **Soil and Water Assessment Tool – User Manual, Version 2000**. Soil And Water Research Laboratory, Agricultural Research Service, Texas, 2002. 472p.

NEITSCH, S.L.; ARNOLD, J.G.; KINIRY, J.R.; WILLIAMS, J.R. **Soil and Water Assessment Tool - Theoretical Documentation, Version 2005**. Texas Water Resources Institute, Texas A&M University System, College Station, Texas. 2005. 476p

NEITSCH, S.L.; ARNOLD, J.G.; KINIRY, J.R.; SRINIVASAN, R.; WILLIAMS, J.R. **Soil and Water Assessment Tool - Input/Output File Documentation, Version 2009**. Technical Report, n. 365. Texas Water Resources Institute, Texas A&M University System, College Station, Texas, 2010. 604p.

NEITSCH, S.L.; ARNOLD, J.G.; KINIRY, J.R.; WILLIAMS, J.R. **Soil and Water Assessment Tool - Theoretical Documentation,Version 2009**. Texas Water Resources Institute, Texas A&M University System, College Station, Texas, Technical Report No. 406, 2011. 618p.

NEVES, F.F. **Análise prospectiva das áreas de risco à erosão na microbacia hidrográfica do Rio Bonito (Descalvado – SP), potencialmente poluidoras por dejetos de granjas**. 2005, 199f. Dissertação (Mestrado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2005.

NG, W.W.; PANU, U.S.; LENNOX, W.C. Comparative studies in problems of missing extreme daily streamflow records. **Journal of Hydrologic Engineering**, v. 14, n. 1, p. 91-100, 2009.

NIMER, E. **Climatologia do Brasil**. 2.ed. Rio de Janeiro: IBGE, 1989. 422p.

NKUNA, T. R.; ODIYO, J. O. Filling of missing rainfall data in Luvuvhu River Catchment using artificial neural networks. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 36, n. 14, p. 830-835, 2011.

NOCEDAL, J.; Wright, S.J. **Numerical Optimization**. 2nd ed. Berlin, New York: Springer-Verlag, 2006. ISBN 978-0-387-30303-1

NOURANI, V. Using artificial neural networks (ANNs) for sediment load forecasting of Talkherood River Mouth. **Journal of Urban and Environmental Engineering**, v.3, n.1, p. 1-6, 2009.

NOURNI, V.; ANDALIB, G. Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches. **Journal of Mountain Science**, v. 12, n. 1, p. 85-100, 2015

NOURANI, V.; KALANTARI, O. Integrated Artificial Neural Network for Spatiotemporal Modeling of Rainfall–Runoff–Sediment Processes. **Environmental engineering science**, v. 2, n. 5, p. 411-422, 2010.

NOURANI, V.; KALANTARI, O.; BAGHANAM, A.H. Two Semidistributed ANN-Based Models for Estimation of Suspended Sediment Load, **Journal of Hydrologic Engineering**, v. 17, n. 12, p. 1368-1380, 2012.

NOURANI, V.; PARHIZKAR, M.; VOUSOUGHI, F.D.; AMINI, B. Capability of Artificial Neural Network for Detecting Hysteresis Phenomenon Involved in Hydrological Processes. **Journal of Hydrologic Engineering**, v. 19, n. 5, p. 896-906, 2014.

OEURNG, C.; SAUVAGE, S.; SANCHEZ-PÉREZ, J.M. Dynamics of suspended sediment transport and yield in a large agricultural catchment, southwest France. **Earth Surface Processes and Landforms**, v. 35, n. 11, p. 1289-1301, 2010.

OLD, G.H.; LEEKS, G.J.L; PACKMAN, J.C.; SMITH, B.P.G.; LEWIS, S.; HEWITT, E.J.; HOLMES, M.; YOUNG, A. The impact of a convectional summer rainfall event on river flow and fine sediment transport in a highly urbanized catchment: Bradford, West Yorkshire. **The Science of the Total Environment**, v. 314-316, p. 495-512, 2003.

OLIVEIRA, G.G. de; PEDROLLO, O.C.; CASTRO, N.M. dos R. **Metodologia de análise de sensibilidade e exclusão de variáveis de entrada em simulação hidrológica por redes neurais artificiais (RNAs): resultados preliminares**. In: XIX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. 19., 27 de novembro a 01 de dezembro de 2011, Maceió (AL). **Anais...** Maceió: ABRH, 2011, p. 1-19.

OLIVEIRA, M.H.C. de; SARI, V.; CASTRO, N.M. dos R.; PEDROLLO, O.C. Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, v. 62, n. 13, p. 2120-2138, 2017. DOI: 10.1080/02626667.2017.1364844

OLIVEIRA, M.Q.C.; MEDEIROS, Y.D.P. Aplicação do modelo SWAT na avaliação de impactos decorrentes da modificação no uso do solo em bacias hidrográficas. In: XIII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. 1999. Belo Horizonte, Minas Gerais. **Anais...** Belo Horizonte: ABRH, 1999.

OLIVEIRA, M.Q.C.; OLIVEIRA, R.C.; MEDEIROS, Y.D.P. Hydrologic Modeling of a Semi-Arid Region in Brazil. In: 3rd INTERNATIONAL SWAT CONFERENCE, 7., Duebendorf. **Proceedings...** Switzerland, 2005a.

OLIVEIRA, N.T. de. **Influência da palha no balanço hídrico em lisímetros**. 2006, 99f. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

OLIVEIRA, N.T. de; CASTRO, N.M. dos R.; GOLDENFUM, J.A. Influência da Palha no Balanço Hídrico em Lisímetros. **Revista Brasileira de Recursos Hídricos**, v. 15, n. 2, p. 93-103, 2010.

OLIVEIRA, R.C.; OLIVEIRA, M.Q.C.; MEDEIROS, Y.D.P. Aplicação do modelo SWAT em região semi-árida. In: XVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, João Pessoa. **Anais...** João Pessoa, Paraíba: ABRH; 2005b.

OLYAIE, E.; BANEJAD, H.; CHAU, K.-W.; MELESSE, A.M. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. **Environmental Monitoring and Assessment**, v. 187-189, p. 1-22, 2015

OVERTON, D.E. Muskingum flood routing of upland streamflow. **Journal of Hydrology**, v. 4, p. 185-200, 1966.

OWENS, P.N. Sediment Behaviour, Functions and Management in River Basins. In: OWENS, P.N. (editor). **Sustainable Management of Sediment Resources: Sediment Management at the River Basin Scale**, v. 4, 2008. p. 1-29.

PAIM, J.B.; MENEZES, J.T. Estimativa do balanço sedimentar da bacia do rio Tijucas (SC-Brasil) a partir da aplicação do modelo hidrológico SWAT. **Revista Geográfica Acadêmica**, v. 3, n. 2, p. 5-14, 2009.

PAIVA, R.C.D. de; PAIVA, E.M.C.D. de. Simulação hidrológica com modelo SWAT na Bacia Menino Deus I, representativa da Mata Atlântica. In: I SIMPÓSIO DE RECURSOS HÍDRICOS DO SUL-SUDESTE, Curitiba. **Anais...** Curitiba, Paraná, 2006.

PARSONS, J.E.; THOMAS, D.L.; HUFFMAN, R.L. **Agricultural non-point source water quality models: their use and application**. Series Bulletin #398, 2004. 195p.

PARTAL, T.; CIGIZOGLU, H.K. Estimation and forecasting of daily suspended sediment data using wavelet–neural networks. **Journal of Hydrology**, v. 358, n. 3-4, p. 317- 331, 2008.

PASHOVA, L.; KOPRINKOVA-HRISTOVA, P.D.; POPOVA, S. Gap filling of daily sea levels by artificial neural networks. *TransNav: International Journal on Marine Navigation and Safety of Sea Transportation*, v. 7, n. 2, 2013.

PERAZZOLI, M.; KAUFMANN, V. Efeitos de cenários de uso do solo sobre o regime hídrico e produção de sedimentos na bacia do Ribeirão Concórdia – SC. **Revista Árvore**, v.37, n.5, p.859-869, 2013.

PEREIRA; D.D.R.; MARTINEZ, M.A.; ALMEIDA, A.Q. de; PRUSKI, F.F.; SILVA, D.D. da; ZONTA, J.H. Hydrological simulation using SWAT model in headwater basin in Southeast Brazil. **Revista Engenharia Agrícola**, v. 34, n. 4, p. 789-799, 2014.

PEREIRA; D.D.R.; MARTINEZ, M.A.; SILVA, D.D. da; PRUSKI, F.F. Hydrological simulation in a basin of typical tropical climate and soil using the SWAT model part I: Calibration and validation tests. **Journal of Hydrology: Regional Studies**, v. 7, p. 14-37, 2016.

PEREIRA, J.M.G.; CAMPANA, N.A.; EID, N.J. Processamento de dados para utilização de modelo matemático de simulação à bacia do rio Jiquiriçá - Bahia. In: XVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, João Pessoa. **Anais...** João Pessoa, Paraíba: ABRH, 2005.

PEREIRA, M.A.; CAUDURO, E.M.C.D de. Monitoramento da turbidez em duas pequenas bacias hidrográficas inseridas no bioma mata atlântica. In: IX ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 16., 2010, Brasília, Distrito Federal. **Anais...** Brasília: ABRH, 2010.

PEREIRA, M.A.; CAUDURO, E.M.C.D de; PAIVA, J.B.D. de. Produção de Sedimentos em Diferentes Escalas Espaço-Temporais de Duas Pequenas Bacias e um Lisímetro no Bioma Mata Atlântica. **Revista Brasileira de Recursos Hídricos**, v. 17, n. 4, p. 49-64, 2012.

PERRY, C.; TAYLOR, K. Environmental sedimentology: introduction. In: PERRY, C. e TAYLOR, K. (Org.). **Environmental sedimentology**. Blackwell Publishing: 2007. p. 1-31.

PFANNKUCHE, J.; SCHMIDT, A. Determination of suspended particulate matter concentration from turbidity measurements: particle size effects and calibration procedures. **Hydrological Processes**, v. 17, n. 10, p. 1951-1963, 2003.

PINHEIRO, E.A.R.; ARAÚJO, J.C. de; FONTENELE, S. de B.; LOPES, J.W.B. Calibração de turbidímetro e análise de confiabilidade das estimativas de sedimento suspenso em bacia semiárida. **Water Resources and Irrigation Management**, v. 2, n. 2, p.103-110, 2013.

PINTO, D.B.F. **Aplicação do modelo SWAT (Soil and Water Assessment Tool) na simulação hidrossedimentológica em bacia hidrográfica da Serra da Mantiqueira, MG**. 2011, 225f. Tese (Doutorado em Engenharia de Água e Solo) - Universidade Federal de Lavras, Lavras, 2011.

PINTO, D.B.F; SILVA, A.M. da; BESKOW, S.; Mello, C.R. de; COELHO, G. Application of the Soil and Water Assessment Tool (SWAT) for sediment transport simulation at a headwater watershed in Minas Gerais state, Brazil. **Transactions of the ASABE**, v. 56, n. 2, p. 697-709, 2013.

POLETO, C.; MERTEN, G.H. Rede de monitoramento e coleta de amostras. In: POLETO, C. e MERTEN, G. H. (org.). **Qualidade dos sedimentos**. Porto Alegre: ABRH, 2006. p. 1-38.

POLETO, K.; SAMPAIO, S.C.; QUEIROZ, M.M.F. de; GOMES, B.M.; SONCELA, S. Turbidimetry as an alternative method to determine the rating curve of suspended sediments. **Engenharia Agrícola**, v.31, n.3, p. 598-606, 2011.

PRADO, T.B.G. **Evolução do uso das terras e produção de sedimentos na bacia hidrográfica do rio Jundiá-Mirim**. 2005, 72f. Dissertação (Mestrado em Agricultura Tropical e Subtropical) – Instituto Agronômico, Campinas, 2005.

PRIESTLEY, C.H.B.; TAYLOR, R.J. On the assessment of surface heat flux and evaporation using large-scale parameters. **Monthly Weather Review**, v. 100, n. 2, p. 81-92, 1972.

PRUIT, B.A. Uses of turbidity by states and tribes. In: GRAY, J.R.; GLYSSON, G.D. (editors). **FEDERAL INTERAGENCY WORKSHOP ON TURBIDITY AND OTHER SEDIMENT SURROGATES**, 16., 2002, Reno, Nevada. **Proceedings....** Nevada: US Geological Survey Circular 1250, 2002. Disponível em: <http://water.usgs.gov/osw/techniques/TSS/listofabstracts.htm>. Acessado em: dezembro 2014.

PULEO, J.A.; JOHNSON, R.V.; BUTT, T.; KOONEY, T.N; HOLLAND, K.T. The effect of air bubbles on optical backscatter sensors. **Marine Geology**, v. 230, p. 87-97, 2006.

RAGHUWANSHI, N.S.; SINGH, R.; REDDY, L.S. Runoff and Sediment Yield Modeling Using Artificial Neural Networks: Upper Siwane River, India. **Journal of Hydrologic Engineering**, v. 11, n. 1, p. 71-79. 2006.

RAI, R.K.; MATHUR, B.S. Event-based Sediment Yield Modeling using Artificial Neural Network. **Water Resources Management**, v. 22, n. 4, p. 423-441, 2008.

RAJAEI, T. Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. **Science of the Total Environment**, v. 409, n. 15, p. 2917-2928, 2011.

RAJAEI, T., MIRBAGHERI, S.A., ZOUNEMAT-KERMANI, M., NOURANI, V. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. **Science Total Environmental**, v. 407, p. 4916-4927, 2009.

RAJAEI, T.; NOURANI, V.; ZOUNEMAT-KERMANI, M.; KISI, O. River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model. **Journal of Hydrologic Engineering**, v. 16, n.8, p. 613-627, 2011.

RASMUSSEN, T.J.; ZIEGLER, A.C.; RASMUSSEN, P.P. **Estimation of constituent concentrations, densities, loads, and yields in lower Kansas River, northeast Kansas, using regression models and continuous water-quality monitoring, January 2000 through December 2003**. U.S. Geological Survey Scientific Investigations Report 2005–5165, 2005. 117p.

RASMUSSEN, P.P.; GRAY, J.R.; GLYSSON, G.D.; ZIEGLER, A.C. Guidelines and Procedures for Computing Time-Series Suspended-Sediment Concentrations and Loads from In-Stream Turbidity-Sensor and Streamflow Data. In: U.S. GEOLOGICAL SURVEY TECHNIQUES AND METHODS. **Book 3- Applications of Hydraulics**, Section C (Sediment and Erosion Techniques), Chapter C4, 2011. 52p.

RAWLS, W.J.; BRAKENSIEK, D.L. Prediction of soil water properties for hydrologic modeling. In: JONES, E.B.; WARD, T.J (eds). **Watershed management in the 80's**. ASCE, New York, N.Y. 1985, p. 293-299.

ROCHA, E.O.; CALIJURI, M.L.; SANTIAGO, A.F.; ASSIS, L.C. de; ALVES, L.G.S. The Contribution of Conservation Practices in Reducing Runoff, Soil Loss, and Transport of

Nutrients at the Watershed Level. **Water Resources Management**, 26, n. 13, p. 3831-3852, 2012.

ROCHA, E.O.; CALIJURI, M.L.; CARVALHO, I. de C.; SILVA, M.D.F.M. Utilização do modelo SWAT no monitoramento de impactos ambientais decorrentes de alterações climáticas. In: XXIV CONGRESSO BRASILEIRO DE CARTOGRAFIA. 9, 2010, Aracaju, SE. **Anais...** Aracaju, 2010.

ROCHA, E. de O. **Estudo Ambiental Integrado de Processos Hidrossedimentológicos e Nutrientes na Bacia Hidrográfica do Rio Piranga Utilizando o SWAT**. 2013, 78f. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Viçosa, Viçosa, 2013.

RODRIGUES, D.F.; REIS, R.S. Aplicação do modelo SWAT na estimativa da produção de sedimentos na bacia hidrográfica do rio Coruripe/AL. In: XVII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. 17., 2007, São Paulo, SP. **Anais...** São Paulo: ABRH, 2007.

ROUHOLAHNEJAD, E.; ABBASPOUR, K.C.; VEJDANI, M.; SRINIVASAN, R.; SCHULIN, R.; LEHMANN, A. A parallelization framework for calibration of hydrological models. **Environmental Modelling & Software**, v. 31, p. 28-36, 2012.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by backpropagating errors. **Nature**, v. 323, p. 533-536, 1986.

SADAR, M.J. **Turbidity science**. Technical Information Series, Booklet n. 11, 1998. 26p.

SALLES, L.A. **Calibração e validação do modelo SWAT para a predição de vazões na bacia do ribeirão Pipiripau**. 2012, 114f. Dissertação (Mestrado em Engenharia Florestal) – Universidade de Brasília, Brasília/DF. 2012.

SALIMI, M.; HASSANZADEH, Y.; DANESHFARAZ, R.; SALIMI, M. Sedimentation Estimation Study Using Artificial Neural Network for Karaj Dam Reservoir in Iran. **Journal of Basic and Applied Scientific Research**, v. 3, n. 8, p. 185-193, 2013

SALOMONS, W.; BRILS, J. **Contaminated Sediments in European River Basins**. 2004. 80p.

SANTOS, I.; ANDRIOLO, M.V.; GIBERTONI, R.C.; KOBIYAMA, M. Use of the SWAT model to evaluate the impact of different land use scenarios on discharge and sediment transport in the Apucarantina River watershed, southern Brazil. **IAHS Publication**, v. 337, p. 322-328, 2010.

SANTOS, J.Y.G. dos; SILVA, R.M. da; MONTENEGRO, S.M.G.L.; SANTOS, C.A.G. Aplicação do modelo SWAT para a estimativa da produção de sedimentos na bacia do rio Tapacurá, Pernambuco. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 19., 2014, João Pessoa, Paraíba. **Anais...** João Pessoa: ABRH, 2014.

SANTOS, R. de O. **Avaliação da produção de sedimentos na bacia hidrográfica do rio Potengi através do modelo SWAT**. 2010, 90f. Dissertação (Mestrado em Engenharia Sanitária) – Universidade Federal do Rio Grande do Norte, Natal, RN, 2010.

SANTOS, R. de O.; SCUDELARI, A.C.; CUNHA, C. de L. da N.; RIGHETTO, A.M. Avaliação da Produção e Aporte de Sedimentos para o Rio Potengi, RN. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 149-163, 2013

SARANGI, A.; MADRAMOOTOO, C.A.; ENRIGHT, P.; PRASHER, S.O.; PATEL, R.M. Performance evaluation of ANN and geomorphology-based models for runoff and sediment yield prediction for a Canadian watershed. **Current Science**, v. 89, n. 12, p. 2022-2033, 2005.

SARI, V. ALESIO, M.; CASTRO, N.M. dos R., KOBİYAMA, M. Calibração de sondas de turbidez em laboratório. In: X ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS (X ENES). 23. 2012, Foz do Iguaçu. **Anais...** Foz do Iguaçu: ABRH-UFPR, 2012.

SARI, V.; CASTRO, N.M. dos R.; KOBİYAMA, M. Estimativa da concentração de sedimentos suspensos com sensores ópticos: Revisão. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 4, p. 816-836, 2015.

SARI, V. CASTRO, N.M. dos R.; PEDROLLO, O.C. Estimate of suspended sediment concentration from monitored data of turbidity and water level using artificial neural networks. **Water Resources Management**, v. 31, n. 15, p. 4909-4923, 2017.
<https://doi.org/10.1007/s11269-017-1785-4>

SARI, V.; PEREIRA, M.A.F.; CASTRO, N.M. dos R.; KOBİYAMA, M. Efeitos do tamanho da partícula e da concentração de sedimentos suspensos sobre a turbidez. **Revista de Engenharia Sanitária e Ambiental**, v. 22, n. 2, p. 213-219, 2017.

SARI, V.; POLETO, C.; CASTRO, N.M. dos R. Caracterização dos processos hidrossedimentológicos em bacias rurais e urbanas. **Enciclopédia Biosfera**, v. 9, n. 16, p. 596-624, 2013.

SARMENTO, L. **Análise de incertezas e avaliação dos fatores influentes no desempenho de modelos de simulação de bacias hidrográficas**. 2010, 241f. Tese (Doutorado em Tecnologia Ambiental e Recursos Hídricos) – Universidade de Brasília, Brasília/DF, 2010.

SCHOELLHAMER, D.H. Biological interference of optical backscatterance sensors in Tampa Bay, Florida. **Marine Geology**, v. 110, n. 3-4, p. 303-13, 1993.

SCHOELLHAMER, D.H.; WRIGHT, S.A. Continuous measurement of suspended-sediment discharge in rivers by use of optical backscatterance sensors. **IAHS Publication**, v. 283, p.28-36, 2003.

SCHULTZ, G.B.; SOUZA, R.M.; SANTOS, I. dos. Simulação da produção e transporte de sedimentos na bacia do Altíssimo rio Negro com o modelo SWAT. In: IX ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS. 9., 2010. Brasília, Distrito Federal. **Anais...** Brasília, 2010.

SHABANI, M.; SHABANI, N. Estimation of daily suspended sediment yield using artificial neural network and sediment rating curve in Kharestan watershed, Iran. **Australian Journal of Basic and Applied Sciences**, v. 6, n. 12, p. 157-164, 2012.

SHANNO, D.F. Conditioning of quasi-Newton methods for function minimization. **Mathematics Computation**, v. 24, n. 11, p. 647-650, 1970.

SHELLENBARGER, G.G.; WRIGHT, S.A.; SCHOELLHAMER, D.H. A sediment budget for the southern reach in San Francisco Bay, CA: Implications for habitat restoration. **Marine Geology**, v. 345, p. 281-93, 2013.

SHIAU, J.-T. ; HSU, H.-T. Suitability of ANN-Based Daily Streamflow Extension Models: a Case Study of Gaoping River Basin, Taiwan. **Water Resources Management**, v. 30, n. 4, p.1499-1513, 2016.

SHIRI, J.; KISI, O. Estimation of daily suspended sediment load by using wavelet conjunction models. **Journal of Hydrologic Engineering**, v. 17, n. 9, p. 986-1000, 2012.

SILVA, A. M.; VALERIANO, D.M. Georreferenciamento e análise da correção atmosférica para o cálculo de albedo usando sensor Landsat ETM+. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9., 2003. Belo Horizonte, **Anais...**Belo Horizonte: INPE, 2003.

SILVA, C.A.I. da. **Análise de aplicabilidade da interface do modelo hidrológico SWAT-SIG no estudo da produção de sedimentos em uma bacia no nordeste do Brasil**. 2014, 53f. Dissertação (Mestrado em Recursos Hídricos e Saneamento) – Universidade Federal de Alagoas, Maceió, 2014.

SILVA, D.T.A. da; SILVA, M.D.; SILVA, T.C. da. Estimativa do aporte de sedimentos na Bacia Hidrográfica do Submédio Rio São Francisco. In: XVII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 2015, João Pessoa, Paraíba. **Anais...** João Pessoa: INPE, 2015.

SILVA, L.R.S. da. **Análise de incertezas e avaliação dos fatores influentes no desempenho de modelos de simulação da bacias hidrográficas.** 223p. 2010. Tese (Doutorado em Tecnologia Ambiental e Recursos Hídricos) – Universidade de Brasília, Faculdade de Tecnologia, Brasília, 2010.

SILVA, M.A. da; DANTAS, J.C.; SILVA, R.M. da. Simulação da vazão e produção de sedimentos usando o modelo SWAT para a bacia do rio Taperoá-PB. In: XI ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS, 15., 2014, João Pessoa, Paraíba. **Anais...** Paraíba: ABRH, 2014.

SILVA, R.M. da; MEDEIROS, I.C. Análise hidrossedimentológica em ambiente SIG usando o modelo SWAT. **GeoFocus - Revista Internacional de Ciencia y Tecnología de la Información Geográfica**, n. 14, p. 211-231, 2014.

SILVA, R.M. da; SANTOS, C.A.G.; SILVA, V.C. de L.M.; PEREIRA e SILVA, L. Erosivity, surface runoff, and soil erosion estimation using GIS-coupled runoff–erosion model in the Mamuaba catchment, Brazil. **Environmental Monitoring and Assessment**, v. 185, n. 11, p. 8977-8990, 2013.

SILVA, V. de A.; MOREAU, M.S.; MOREAU, A.M.S. dos S.; REGO, N.A.C. Uso da terra e perda de solo na Bacia Hidrográfica do Rio Colônia, Bahia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 3, p. 310-315, 2011.

SINGH, A.; IMTIYAZ, M.; ISAAC, R.K.; DENIS, D.M. Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. **Agricultural Water Management**, v. 104, p. 113-120, 2012.

_____. Comparison of Artificial Neural Network Models for Sediment Yield Prediction at Single Gauging Station of Watershed in Eastern India. **Journal of Hydrologic Engineering**, v. 18, n. 1, p. 115-120, 2013.

SINGH, G.; PANDA, R.K. Daily Sediment Yield Modeling with Artificial Neural Network using 10-fold Cross Validation Method: A small agricultural watershed, Kaptari, India.

International Journal of Earth Sciences and Engineering, v. 04, n. 06 SPL, p. 443-450, 2011.

SINGH, V.P.; FREVERT, D.K. Mathematical modeling of watershed hydrology. In: SINGH, V.P. e FREVERT, D.K. (editors). **Mathematical Models of large watershed hydrology**. United States of America: Water Resources Publications, LLC. ISBN Number 1-887201-34-3, 2002. p. 1-66.

_____. **Watershed models**. United States of America: CRC Press, ISBN 0-8493-3609-0, 2006. p. 3-19.

SINGH, V.P.; WOOLHISER, D.A. Mathematical Modeling of Watershed Hydrology. **Journal of Hydrologic Engineering**, v. 7, n. 4, p. 270-292, 2002.

SIQUEIRA, M. da S. de; ALCÂNTARA, H.M. de. Estimativa da produção de sedimentos em pequenas bacias não instrumentadas no semiárido usando o modelo SWAT. In: CONGRESSO TÉCNICO CIENTÍFICO DA ENGENHARIA E DA AGRONOMIA, 4., 2015, Fortaleza, Ceará. **Anais...** Fortaleza, 2015.

SLAETS, J.I.F.; SCHMITTER, P.; HILGER, T.; LAMERS, M.; PIEPHO, H-P.; VIEN, T.D.; CADISCH, G. A turbidity-based method to continuously monitor sediment, carbon and nitrogen flows in mountainous watersheds. **Journal of Hydrology**, v. 513, p. 45-57, 2014.

SLOAN, P.G.; MOORE, I.D. Modeling subsurface stormflow on steeply sloping forested watersheds. **Water Resources Research**, v. 20, n. 12, p. 1815-1822, 1984.

SOUZA, C.F.; DORNELLES, A.M.; ACIOLI, L.A.; MERTEN, G. Comparação dentre estimativas de produção de sedimentos na Bacia do Rio Potiribu. In: VII ENCONTRO NACIONAL DE ENGENHARIA DE SEDIMENTOS -ENES, 20., 2006. Porto Alegre, Ri Grande do Sul. **Anais...** Porto Alegre, 2006.

STRAUCH, M.; LIMA, J.E.F.W.; VOLK, M.; LORZ, C.; MAKESCHIN, F. The impact of Best Management Practices on simulated streamflow and sediment load in a Central Brazilian catchment. **Journal of Environmental Management**, v. 127, special issue, p. S24-S36, 2013.

SU, C.-C.; Lu, J.-Y.; Hong, J.-H. A field investigation of the sediment transport characteristics of a high sediment load intermittent river in Taiwan. **Hydrological Processes**, v. 27, n. 26, p. 4043-4056, 2013.

SUMMER, W.; WALLING, D.E. **Modelling erosion, sediment transport and sediment yield**. UNESCO. IHP-VI Technical Documents in Hydrology, n. 60, 2002

SUTHERLAND, T.F.; LANE, P.M.; AMO, C.L.; DOWNING, J. The calibration of optical backscatter sensors for suspended sediment of varying darkness levels. **Marine Geology**, v.162, n. 2-4, p. 587-97, 2000.

TABARI, H.; TALAEI, P.H. Reconstruction of river water quality missing data using artificial neural networks. **Water Quality Research Journal of Canada**, v. 50, n. 4, p. 326-335, 2015. DOI: 10.2166/wqrjc.2015.044

TALEBIZADEH, M.; SEYYED, S.M.; AYYOUBZADEH, A.; GHASEMZADEH, M. Uncertainty Analysis in Sediment Load Modeling Using ANN and SWAT Model. **Water Resources Management**, v. 24, n. 9, p. 1747-1761, 2010.

TANANAIEV, N.I.; DEBOLSKIY, M.V. Turbidity observations in sediment flux studies: Examples from Russian rivers in cold environments. **Geomorphology**, v. 218, p. 63-71, 2014.

TAYLOR K. G. ; OWENS, P. N. ; BATALLA, R. J.; GARCIA, C. Sediment and Contaminant Sources and Transfers in River Basins. In: OWENS, P.N. (editor). **Sustainable Management of Sediment Resources: Sediment Management at the River Basin Scale**, v. 4, 2008. p. 83-135.

TEIXEIRA, L.C.; PAIVA, J.B.D. de; PEREIRA, J.E. da S.; LISBÔA, R. de M. Relationship between turbidity and suspended sediment concentration from a small hydrographic basin in Santa Maria (Rio Grande do Sul, Brazil). **International Journal of River Basin Management**, v. 14, n. 4, p. 393-399, 2016.

TENA, A.; BATALLA, R.J.; VERICAT, D.; LÓPEZ-TARAZÓN, J.A. Suspended sediment dynamics in a large regulated river over a 10-year period (the lower Ebro, NE Iberian Peninsula). **Geomorphology**, v. 125, n. 1, p. 73-84, 2011.

TÓTH, B.; BÓDIS, E. Estimation of suspended loads in the Danube River at Göd (1668 river km), Hungary. **Journal of Hydrology**, v. 523, p. 139-146, 2015.

TUCCI, C.E.M. **Modelos hidrológicos**. 2 ed., Porto Alegre: Ed. da UFRGS/ ABRH, 2005. 678p.

UHRICH, M.A.; BRAGG, H.M. **Monitoring instream turbidity to estimate continuous suspended-sediment loads and yields and clay-water volumes in the Upper North**

Santiam River Basin, Oregon, 1998–2000. U.S. Geological Survey Water-Resources Investigations Report 03–4098, 2003. 43 p.

ULKE, A.; TAYFUR, G.; OZKUL, S. Predicting Suspended Sediment Loads and Missing Data for Gediz River, Turkey. **Journal of hydrologic engineering**, v. 14, n. 9, p. 954-965, 2009

UNESCO (Organização das Nações Unidas para a educação). **Sediment Issues & Sediment Management in Large River Basins Interim: Case Study Synthesis Report.** International Sediment Initiative. Technical Documentation in Hydrology, 2011. 82p.

USTOORIKAR, K.; DEO, M.C. Filling up gaps in wave data with genetic programming. **Marine Structures**, v. 21, n. 2, p. 177-19, 2008.

UZEIKA, T. **Aplicabilidade do modelo SWAT (*Soil and Water Assessment Tool*) na simulação da produção de sedimentos em uma pequena bacia hidrográfica rural.** 2009, 129f. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

UZEIKA, T.; MERTEN, G.H.; MINELLA, J.P.G.; MORO, M. Use of the Swat Model for Hydro-Sedimentologic Simulation in a Small Rural Watershed. **Revista Brasileira de Ciências do Solo**, v. 36, n. 2, p. 557-565, 2012.

VAN GRIENSVEN, A.; BAUWENS, W. Multiobjective autocalibration for semidistributed water quality models. **Water Resources Research**, v. 39, n. 12, p. 1348-1356, 2003.

VAN GRIENSVEN, A.; MEIXNER, T.; GRUNWALD, S.; BISHOP, T.; DILUZIO, M.; SRINIVASAN, R. A global sensitivity analysis tool for the parameters of multivariable catchment models. **Journal of Hydrology**, v. 324, n. 1/4, p. 10-23, 2006.

VANONI, V.A. **Sedimentation Engineering.** New York: Headquarters of the Society, 1975. p. 587-612.

VEIGA, A.M. **Calibração do modelo hidrossedimentológico SWAT na bacia hidrográfica do Córrego Samambaia.** 2014, 125f. Dissertação (Mestrado em Engenharia do Meio Ambiente) – Universidade Federal de Goiás, Goiânia, 2014.

VESTENA, L.R.; LUCINI, H.; KOBIYAMA, M. Monitoramento automático da concentração de sedimentos em suspensão na bacia hidrográfica do Caeté, Alfredo Wagner/SC. In: VI

SIMPÓSIO NACIONAL DE GEOMORFOLOGIA REGIONAL CONFERENCE ON GEOMORPHOLOGY, 6., 2006, Goiânia. **Anais...** Goiana: UGB/IAG, 2006.

VIERO, A.C. **Análise da geologia, geomorfologia e solos no processo de erosão por voçorocas: bacia do Taboão/RS**. 2004, 119f. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

VOGL, T.P.; MANGIS, J.K.; RIGLER, A.K.; ZINK, W.T.; ALKON, D.L. Accelerating the Convergence of the Back-Propagation Method. **Biological Cybernetics**, v. 59, n. 4, p. 257-263, 1988.

VOUSDOUKAS, M.I.; ALEKSIADIS, S.; GRENZ, C.; VERNEY, R. Comparisons of acoustic and optical sensors for suspended sediment concentration measurements under non-homogeneous solutions. **Journal of Coastal Research**, v. 30, n. 2, p. 160-164, 2011.

WALLING, D.E. Assessing the accuracy of suspended sediment rating curves for a small basin. **Water Resources Research**, v. 13, n. 3, p. 531-538, 1977.

WANG, Y.-M.; TRAORE, S.; KERH, T. Monitoring Event-Based Suspended Sediment Concentration by Artificial Neural Network Models. **WSEAS Transactions on Computers**, v. 7, n. 5, p. 559-568, 2008.

WANG, Y.-M.; KERH, T.; TRAORE, S. Neural networks approaches for modelling river suspended sediment concentration due to tropical storms. **Global NEST Journal**, v. 11, n. 4, p. 457-466, 2009.

WANG, Y.-M.; TRAORE, S. Time-lagged recurrent network for forecasting episodic event suspended sediment load in typhoon prone area. **International Journal of Physical Sciences**, v. 4, n. 9, p. 519-528, 2009.

WHITE, S.M.; APITZ, S.E. Conceptual and Strategic Frameworks for Sediment Management at the River Basin Scale. In: OWENS, P.N. (editor). **Sustainable Management of Sediment Resources: Sediment Management at the River Basin Scale**, v. 4, 2008. p. 31-53.

WIDROW, B.; HOFF, M. E. Adaptive Switching Circuits. **Ire Wescon Convention Record**, v.4, p. 96-104, 1960.

WILLIAMS, J.R. Flood routing with variable travel time or variable storage coefficients. **Transactions of the ASAE**, v. 12, n. 1, p. 100-103, 1969.

_____. Sediment-yield prediction with universal equation using runoff energy factor. In: **SEDIMENT YIELD WORKSHOP**. Present and prospective technology for predicting sediment yield and sources, 9., 1975, Oxford. **Proceedings...** Oxford: USDA Sedimentation Laboratory, ARS-S-40, 1975.

_____. SPNM, a model for predicting sediment, phosphorus, and nitrogen yields from agricultural basins. **Water Resources Bulletin**, v. 16, n. 5, p. 843-848, 1980.

WISCHMEIER, W.H.; SMITH, D.D. **Predicting rainfall-erosion losses from cropland east of the Rocky Mountains**: guide for selection of practices for soil and water conservation. USDA-ARS, Agriculture Handbook 282, 1965. 47p.

_____. **Predicting rainfall erosion losses- a guide to conservation planning**. USDA-ARS, Agriculture Handbook 537, 1978. 67p.

WMO (World Meteorological Organization). **Manual on Sediment Management and Measurement**. Por: Yang Xiaoqing. Operational Hydrology Report n. 47, Geneva , Switzerland, 2003. 159p.

_____. **Guide to Hydrological Practices**. Volume I, Hydrology – From Measurement to Hydrological Information. WMO n. 168. Sixth edition, 2008. 296p.

XAVIER, F.V. **Contribuição metodológica ao estudo da produção e distribuição espacial de sedimentos na bacia hidrográfica do Rio Manso, utilizando o modelo AVSWAT**. 2009, 167f. Dissertação (Mestrado m Física Ambiental) – Instituto de Ciências Exatas e da Terra, Universidade Federal de Mato Grosso, Cuiabá, 2009.

YANG, T.-M.; FAN, S.-H.; FAN, C.; HSU, N.-H. Establishment of turbidity forecasting model and early-warning system for source water turbidity management using back-propagation artificial neural network algorithm and probability analysis. **Environmental Monitoring and Assessment**, v. 186, p. 4925-4934, 2014.

YITIAN, L.; GU, R.R. Modeling Flow and Sediment Transport in a River System Using an Artificial Neural Network. **Environmental Management**, v. 31, n. 1, pp. 122–134

YENIGÜN, K.; BILGEHAN, M.; GERGER, R.; MUTLU, M. A comparative study on prediction of sediment yield in the Euphrates basin. **International Journal of the Physical Sciences**, v. 5, n. 5, p. 518-534, 2010

ZANIN, P.R. **Modelagem hidrossedimentológica de bacia hidrográfica com reservatórios**. 2015, 209f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2015.

ZANELLA, B. P. **Modelagem do aporte de sedimentos aplicada à bacia hidrográfica contribuinte da PCH Costa Rica (MS) e proposta de mitigação do assoreamento**. 2016, 142f. Tese (Doutorado em Engenharia Mecânica) - Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2016.

ZAW, Z.; HARTMUT, W. Improving Flood Forecasting in a Developing Country: A Comparative Study of Stepwise Multiple Linear Regression and Artificial Neural Network. **Water Resources Management**, v. 28, n. 8, p: 2109-2128, 2014.

ZHANG, L.; O'NEILL, A.L.; LACEY, S. Modelling approaches to the prediction of soil erosion in catchments. **Environmental Software**, v. 11, n. 1-3, p. 123-133, 1996

ZHU, Y.-M.; LU, X.X.; ZHOU, Y. Sediment flux sensitivity to climate change: A case study in the Longchuanjiang catchment of the upper Yangtze River, China. **Global and Planetary Change**, v. 60, n. 3-4, p. 429-442, 2008.

ZHU, Y.-M.; LU, X.X.; ZHOU, Y. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. **Geomorphology**, v. 84, n. 1-2, p. 111-125, 2007.

ZIEGLER, A.D.; BENNER, S.G.; TANTASIRIN, C.; WOOD, S.H.; SUTHERLAND, R.A.; SIDLE, R.C.; JACHOWSKI, N.; NULLET, M.A.; XI, L.X.; SNIDVONGS, A.; GIAMBELLUCA, T.W.; FOX, J.M. Turbidity-based sediment monitoring in northern Thailand: Hysteresis, variability, and uncertainty. **Journal of Hydrology**, v. 519, part B, p. 2020-2039, 2014.

ANEXOS

ANEXO A - PRINCIPAIS EQUAÇÕES PARA SIMULAÇÃO DOS PROCESSOS HIDROSEDIMENTOLÓGICOS NO MODELO SWAT

As simulações hidrológicas realizadas pelo modelo SWAT podem ser separadas em duas partes: fase terrestre e fase de propagação do ciclo hidrológico. Informações mais detalhadas acerca desses processos e dos parâmetros de entrada do modelo podem ser encontradas em Neitsch et al. (2002, 2005, 2010, 2011) e Arnold et al. (2012a). A seguir são apresentadas as principais equações utilizadas pelo modelo para a modelagem do escoamento superficial e da produção de sedimentos.

A hidrologia terrestre é equacionada por uma equação de balanço hídrico (equação 1), considerando quatro processos principais: escoamento superficial, evapotranspiração, movimento da água no solo e água subterrânea. A subdivisão da bacia permite a representação dos valores evapotranspirados por cada uma das culturas e por cada tipo de solo presente na bacia (NEITSCH et al., 2002, 2005, 2011).

$$SW_t = SW_0 + \sum_{t=1}^t (R_{day} - Q_{surf} - E_a - w_{seep} - Q_{gw}) \quad (1)$$

Onde: SW_t é o conteúdo final de água no solo (mmH_2O); SW_0 é o conteúdo inicial de água no solo no dia i (mmH_2O); t é o tempo t (dias); R_{day} é a quantidade precipitada no dia i (mmH_2O); Q_{surf} é a quantidade escoada superficialmente no dia i (mmH_2O); E_a é a evapotranspiração no dia i (mmH_2O); w_{seep} é a quantidade de água que entra na zona vadosa do perfil do solo, no dia i (mmH_2O); e Q_{gw} é a quantidade de água proveniente do fluxo de retorno, no dia i (mmH_2O).

O escoamento superficial pode ser estimado pelo método de infiltração de Green & Ampt (GREEN e AMPT, 1911) ou do *Soil Conservation Service* (SCS) (NEITSCH et al., 2005). Na equação 2 apresenta-se a formulação para a infiltração acumulada pelo método de Green & Ampt, modificado por Mein e Larson (1973), que foi utilizado nessa pesquisa. A infiltração acumulada ao longo do tempo é uma função do volume infiltrado o qual, por sua vez, é uma função das taxas de infiltração em cada tempo.

$$F_{inf,t} = F_{inf,t-1} + K_e \cdot \Delta t + \Psi_{wf} \cdot \Delta \theta_V \cdot \ln \left(\frac{F_{inf,t} + \Psi_{wf} \cdot \Delta \theta_V}{F_{inf,t-1} + \Psi_{wf} \cdot \Delta \theta_V} \right) \quad (2)$$

Onde: $F_{inf,t}$ é a taxa de infiltração acumulada no tempo t (mmH_2O); $F_{inf,t-1}$ é a taxa de infiltração acumulada no tempo $t-1$ (mmH_2O); K_e é a condutividade hidráulica (mm/h); Ψ_{wf} é o

potencial matricial da frente de umedecimento (mm); $\Delta\theta_v$ é o a mudança no teor de umidade volumétrica relativo à frente de umedecimento (mm/mm)

O parâmetro de condutividade hidráulica (K_e) é aproximadamente a metade da condutividade hidráulica saturada do solo, (K_{sat}) (BOUWER, 1969). A equação 3 é utilizada para o cálculo da condutividade hidráulica (NEARING et al, 1996).

$$K_e = \frac{56,82 \cdot K_{sat}^{0,286}}{1 + 0,051 \cdot \exp^{(0,062 \cdot CN)}} - 2 \quad (3)$$

Onde: K_e é a condutividade hidráulica efetiva (mm/h), K_{sat} é a condutividade hidráulica saturada (mm/h) e; CN é o parâmetro da curva número.

O potencial mátrico da frente de umedecimento é calculado em função da porosidade e dos percentuais de areia e argila, conforme a equação 4 (RAWLS e BRAKENSIEK, 1985):

$$\begin{aligned} \psi_{wf} = & 10 \cdot \exp[6,5309 - 7,32561 \phi_{soil} + 0,001583 \cdot m_c^2 + 3,809479 \cdot \phi_{soil}^2 + \\ & 0,000344 \cdot m_s \cdot m_c - 0,049837 \cdot m_s \cdot \phi_{soil} + 0,001608 \cdot m_s^2 \cdot \phi_{soil}^2 + \\ & 0,001602 \cdot m_c^2 \cdot \phi_{soil}^2 - 0,0000136 m_s^2 \cdot m_c - 0,003479 \cdot m_c^2 \cdot \phi_{soil} - 0,000799 m_s^2 \cdot \phi_{soil}] \end{aligned} \quad (4)$$

Onde: ϕ_{soil} é a porosidade do solo (mm/mm); m_c é o percentual de argila e; m_s é o percentual de areia.

A alteração no teor de umidade volumétrica relativo à frente de umedecimento é calculado no início de cada dia pela equação 5:

$$\Delta\theta_v = \left(1 - \frac{SW}{FC}\right) * (0,95 \cdot \phi_{soil}) \quad (5)$$

Onde: $\Delta\theta_v$ é a alteração no teor de umidade volumétrica relativo à frente de umedecimento (mm/mm); SW é o teor de água em todo o perfil solo, excluindo a quantidade de água mantida no perfil no ponto de murchamento (mmH₂O); FC é a quantidade de água no perfil do solo à capacidade de campo (mmH₂O) e; ϕ_{soil} é a porosidade do solo (mm/mm).

Se um evento de precipitação estiver em andamento à meia-noite, $\Delta\theta_v$ é calculado pela equação 6:

$$\Delta\theta_v = 0,001 * (0,95 \cdot \phi_{soil}) \quad (6)$$

Para cada passo de tempo, o SWAT calcula a quantidade de água no solo. A água que não infiltra torna-se escoamento superficial.

A infiltração, a evapotranspiração e o escoamento superficial são afetados, significativamente, pela quantidade de água retida no dossel da vegetação. No modelo, a quantidade máxima de água que pode ficar retida nas copas das plantas pode variar dia-a-dia, em função do índice de área foliar, conforme a equação 7 (NEITSCH et al., 2011):

$$can_d = can_{max} * \frac{LAI}{LAI_{max}} \quad (7)$$

Onde: can_d é a quantidade máxima de água que pode ser retida nas copas em um dia qualquer (mm); can_{max} é a quantidade máxima de água que pode ser retida nas copas quando o dossel está totalmente desenvolvido (mm); LAI é o índice de área foliar para um dia qualquer; e LAI_{max} é o índice máximo de área foliar para a planta.

Para o cálculo da evapotranspiração potencial, o modelo disponibiliza três métodos: i) Penman-Monteith (MONTEITH, 1965); ii) Priestley - Taylor (PRIESTLEY e TAYLOR, 1972) e; iii) Hargreaves & Samani (HARGREAVES, HARGREAVES e RILEY, 1985).

O tempo de concentração, calculado pela equação 8, representa a quantidade de tempo desde o início da chuva até o momento no qual toda a área da bacia está contribuindo para a vazão, sendo diretamente relacionado ao tamanho da bacia (NEITSCH et al., 2011).

$$t_{ch} = \frac{0,62 * L * n^{0,75}}{A^{0,125} * slp_{ch}^{0,375}} \quad (8)$$

Onde: t_{ch} é o tempo de concentração da vazão no canal (h); L é o comprimento do canal do ponto mais distante até o exutório da sub-bacia (km); n é o coeficiente de rugosidade de Manning para o canal; A é a área da sub-bacia (km²) e; slp_{ch} é a declividade do canal (m/m).

Para grandes bacias, onde o tempo de concentração é maior que um dia, somente uma parcela do escoamento superficial chega ao canal principal no dia em que é gerado. O SWAT tem um recurso de armazenamento para o volume que não chega ao canal principal no mesmo dia em que é gerado. A quantidade de escoamento superficial liberado para o canal principal é calculada pela equação 9 (NEITSCH et al., 2011):

$$Q_{surf} = (Q'_{surf} + Q_{stor,i-1}) * \left(1 - \exp\left[\frac{-surlag}{t_{conc}} \right] \right) \quad (9)$$

Onde Q_{surf} é a quantidade de escoamento superficial liberada para o canal principal em um dia qualquer (mm); Q'_{surf} é a quantidade de escoamento superficial gerada em uma bacia em um dia qualquer (mm); $Q_{stor,i-1}$ é o escoamento superficial armazenado ou atrasado do dia anterior (mm), $surlag$ é o atraso do escoamento superficial; e t_{conc} é o tempo de concentração para a bacia (h).

Em áreas com solos de alta condutividade hidráulica nas camadas superficiais e com camadas impermeáveis ou semipermeáveis, o escoamento lateral pode ser significativo. O modelo SWAT incorpora um modelo de armazenamento cinemático para o escoamento lateral (SLOAN e MOORE, 1984), que simula o fluxo de subsuperfície (escoamento lateral) em uma

seção transversal bidimensional, ao longo de um caminho de fluxo para baixo, por uma encosta íngreme. O volume drenável na zona saturada do segmento da encosta por unidade de área, SW_{ly} , em excesso, é calculado pela equação 10 e o escoamento lateral pela equação 11

$$SW_{ly,excess} = \frac{1000 * H_0 * \theta_d * L_{hill}}{2} \quad (10)$$

$$Q_{lat} = 0,024 * \left(\frac{2 * SW_{ly,excess} * K_{sat} * slp}{\theta_d * L_{hill}} \right) \quad (11)$$

Onde: Q_{lat} é o escoamento lateral (mm/dia); $SW_{ly,excess}$ é o volume da lâmina drenável na zona saturada da encosta por unidade de área (mm); K_{sat} é a condutividade hidráulica saturada (mm/h); slp (slope) é a inclinação introduzida no modelo SWAT como o aumento na elevação por unidade de distância; θ_d é a porosidade drenável do solo (mm/mm); L_{hill} é o comprimento de rampa (m).

Para simular o escoamento que percola em cada camada de solo, o modelo SWAT utiliza uma técnica de propagação do armazenamento, combinada com um modelo de fluxo em fendas. Para a água que percola para baixo da zona das raízes, o volume é armazenado como água subterrânea ou surge como escoamento de retorno à jusante do ponto considerado. A quantidade de água que percola para a próxima camada é calculada pela equação 12 (NEITSCH et al., 2011):

$$W_{perc,ly} = SW_{ly,excess} * \left(1 - \exp\left(-\frac{\Delta t}{TT_{perc}}\right) \right) \quad (12)$$

Onde: $W_{perc,ly}$ corresponde à quantidade de água que percola para a próxima camada (mm); $SW_{ly,excess}$ é o volume da lâmina drenável de água na camada de solo (mm); Δt é a duração do passo de tempo (h) e; TT_{perc} é o tempo de propagação na camada i (h).

O volume de água disponível para percolação $SW_{ly,excess}$, na camada de solo é calculado pela equação 13 (NEITSCH et al., 2011):

$$\begin{aligned} SW_{ly,excess} &= SW_{ly} - FC_{ly} \text{ se } SW_{ly} > FC_{ly} \\ SW_{ly,excess} &= 0 \text{ se } SW_{ly} < FC_{ly} \end{aligned} \quad (13)$$

Onde: SW_{ly} é o conteúdo da lâmina de água na camada de solo (mm); FC_{ly} é o conteúdo da lâmina de água na camada de solo na capacidade de campo (mm).

O tempo de propagação em cada camada de solo (TT_{perc}) é calculado pela equação 14 (NEITSCH et al., 2011):

$$TT_{perc} = \frac{SAT_{ly} - FC_{ly}}{K_{sat}} \quad (14)$$

Onde: SAT_{ly} corresponde à quantidade de lâmina de água na camada de solo quando completamente saturado (mm) e; K_{sat} é a condutividade hidráulica saturada (mm/h).

O modelo SWAT simula dois tipos de aquíferos em cada sub-bacia. O primeiro é um aquífero não confinado (lençol freático), que possui o nível de água do próprio lençol como limite superior, podendo haver fluxo de água para a franja capilar. Este tipo de aquífero contribui com a vazão do canal principal ou do tributário presente na sub-bacia. O outro tipo é o confinado. O modelo considera que a água presente neste tipo de aquífero irá contribuir com a vazão de um canal em uma bacia hidrográfica diferente da estudada (NEITSCH et al., 2011).

O balanço hídrico para o aquífero raso é dado pela equação 15 (NEITSCH et al., 2011):

$$aq_{sh,i} = aq_{sh,i-1} + W_{rchrg} - Q_{gw} - W_{revap} - W_{deep} - W_{pump,sh} \quad (15)$$

Onde: $aq_{sh,i}$ é a quantidade de água armazenada no aquífero raso no dia i (mm); $aq_{sh,i-1}$ é a quantidade de água armazenada no aquífero raso no dia $i-1$ (mm); W_{rchrg} é a quantidade de recarga do aquífero entram no dia i (mm); Q_{gw} é o escoamento de retorno (mm); W_{revap} é o escoamento que retorna ao perfil do solo no dia i (mm); W_{deep} é a infiltração para o aquífero profundo no dia i (mm) e; $W_{pump,sh}$ é a quantidade de água retirada do aquífero raso bombeando no dia i (mm), ou o uso da água.

A água proveniente do escoamento de base contribui no canal principal somente nos casos em que a água armazenada no aquífero raso ultrapassa um limite previamente estabelecido pelo usuário, aq_{shthr} . O escoamento de base é calculado pela seguinte equação 16 (NEITSCH et al., 2011):

$$Q_{gw} = \frac{8000 * K_{sat}}{L_{gw}^2} * h_{wtbl} \quad (16)$$

Onde: Q_{gw} é o escoamento de retorno (mm); K_{sat} é a condutividade hidráulica do aquífero (mm/dia); L_{gw} é o comprimento do dreno (m) e; h_{wtbl} é a cota piezométrica (m).

Quando as camadas de solo acima do lençol freático vão perdendo umidade, a água da superfície do lençol se movimenta para a franja capilar, para depois evaporar para a zona insaturada do solo. Dessa forma, o modelo SWAT simula o movimento da água do lençol para a zona insaturada do solo em função da evapotranspiração demandada, denominando esse movimento como revap. O revap só ocorre quando a quantidade de água armazenada no aquífero é maior do que o limite estabelecido, sendo calculado em escala diária. É possível simular também a retirada de água do lençol freático para irrigação, se os parâmetros forem fornecidos ao modelo (NEITSCH et al., 2005, 2011).

Assim sendo, o revap somente irá ocorrer se a quantidade de água existente no aquífero raso exceder um limite especificado pelo usuário do modelo. A quantidade máxima de água que pode ser removida do aquífero por revap em um dia qualquer é calculada pela seguinte equação 17 (NEITSCH et al., 2011):

$$W_{revap,max} = \beta_{rev} * E_0 \quad (17)$$

Onde: $W_{revap,max}$ é a quantidade máxima de água que é retirada do aquífero (mm); β_{rev} é o coeficiente de revap e; E_0 é a evapotranspiração potencial (mm).

Uma fração da recarga diária pode percolar até o aquífero profundo. A água que atinge o aquífero profundo não é considerada no balanço hídrico, sendo caracterizada como água que sai do sistema. O balanço hídrico para o aquífero profundo é fornecido pela equação 18 (NEITSCH et al., 2011):

$$aq_{dp,i} = aq_{dp,i-1} + W_{deep} - W_{pump,dp} \quad (18)$$

Onde: $aq_{dp,i}$ é a quantidade de água armazenada no aquífero profundo no dia i (mmH₂O); $aq_{dp,i-1}$ é a quantidade de água armazenada no aquífero profundo no dia i-1 (mmH₂O); W_{deep} é a quantidade de água infiltrada no aquífero raso para o aquífero profundo no dia i (mmH₂O) - Infiltração para o aquífero profundo e; $W_{pump,dp}$ é a quantidade de água retirada do aquífero profundo pelo bombeamento do dia i (mmH₂O), ou seja, uso da água.

A simulação da propagação no canal utiliza informações acerca do comprimento, da declividade, da profundidade, da declividade lateral e do Coeficiente de Manning do canal, além da declividade e do Coeficiente de Manning da margem de inundação. O modelo emprega a Equação de Manning para calcular a vazão e a velocidade do escoamento dos rios. A propagação de água pelos canais pode ser calculada pelo Método da Acumulação Variada (WILLIAMS, 1969), ou pelo Método de Muskingum.

A vazão e velocidade no segmento do canal, para um período de tempo, são dadas, respectivamente, pelas equações 19 e 20 (Equação de Manning):

$$q_{ch} = \frac{A_{ch} * R_{ch}^{2/3} * slp_{ch}^{1/2}}{n} \quad (19)$$

$$v_c = \frac{R_{ch}^{2/3} * slp_{ch}^{1/2}}{n} \quad (20)$$

Onde: q_{ch} é a vazão no canal (m³/s); A_{ch} é a área seccional em que ocorre a vazão no canal (m²); R_{ch} é o rio hidráulico do canal para uma determinada profundidade (m); slp_{ch} é a declividade ao longo do comprimento do canal (m/m); n é o Coeficiente de Manning para o canal e; v_c é a velocidade do fluxo no canal (m/s).

O modelo considera que os canais possuem formato trapezoidal, com taludes com inclinação na proporção de 2:1 (horizontal: vertical). O usuário deve informar o comprimento, a largura e a profundidade do canal quando preenchido até o nível mais alto anterior à inundação (extravasamento para fora do canal), além do Coeficiente de Manning e a declividade do canal ao longo de seu comprimento (NEITSCH et al., 2011).

As perdas de água do canal são calculadas por transmissão e evaporação. O modelo também calcula a quantidade de água que entra no trecho de armazenamento do canal e o volume de água que retorna ao canal pelo escoamento de base. As equações para obtenção destes valores estão descritas em Neitsch et al. (2005, 2011). Assim, é possível calcular o balanço hídrico no canal no fim de cada período pela equação 21 (NEITSCH et al., 2011):

$$V_{stored,2} = V_{stored,1} + V_{in} - V_{out} - t_{loss} + E_{ch} + div + V_{bnk} \quad (21)$$

Onde $V_{stored,2}$ é o volume de água no canal no final do período considerado (m^3H_2O); $V_{stored,1}$ é o volume de água no canal no início do mesmo período (m^3H_2O); V_{in} é o volume de água que entra no canal no período em questão (m^3); V_{out} é o volume de água que sai do canal no período em questão (m^3); t_{loss} é a quantidade de água que sai do canal por transmissividade (m^3); E_{ch} é a água evaporada do canal para o período (m^3); div é o volume de água adicionada ou removida do canal para diferentes usos (m^3) e; V_{bnk} é o volume de água adicionada ao canal pelo banco de armazenamento (m^3).

A produção de sedimentos gerada pelo escoamento superficial é estimada para cada HRU através da Equação Universal de Perda de Solo Modificada (MUSLE), descrita na equação 22 (WILLIAMS, 1975):

$$S = 11,8 \cdot (Q_{surf} \cdot q_{peak} \cdot A_{HRU})^{0,56} \cdot K \cdot C \cdot P \cdot LS \cdot CFRG \quad (22)$$

Onde: S é a produção de sedimentos em um dado dia (ton), Q_{surf} é o volume de escoamento superficial ($mm \cdot ha^{-1}$), q_{peak} é a vazão de pico ($m^3 \cdot s^{-1}$), A_{HRU} é a área da HRU (ha), K é o fator de erodibilidade do solo, C é o fator de manejo e cobertura do solo, P é o fator práticas conservacionistas, LS é o fator topográfico, e $CFRG$ é o fator de partículas grossas do solo.

A vazão de pico é a máxima taxa de escoamento superficial que ocorre em um determinado evento, e é calculada no modelo através de uma modificação do método racional, conforme mostrado na equação 23:

$$q_{peak} = \frac{\alpha_{rc} \cdot Q_{surf} \cdot Area}{3,6 \cdot t_{conc}} \quad (23)$$

Onde: q_{peak} é a taxa de escoamento de pico (m^3s^{-1}), α_{tc} é a parcela da chuva diária que ocorre durante o tempo de concentração, Q_{surf} é o escoamento superficial (mm), Area é a área da sub-bacia (km^2), e t_{conc} é o tempo de concentração da sub-bacia (h).

No canal, são simulados dois processos relacionados aos sedimentos: deposição e degradação. A máxima quantidade de sedimentos que pode ser transportada varia em função da velocidade de pico do canal e dos fatores de erodibilidade e de cobertura vegetal do leito (NEITSCH et al., 2011).

Williams (1980) usou as definições de Bagnold (1977) para determinação da degradação no canal, em função da velocidade de pico e da declividade desse canal. A velocidade de pico no canal é calculada pela equação 24 e a vazão de pico no canal é dada pela equação 25:

$$v_{ch,pk} = \frac{q_{ch,pk}}{A_{ch}} \quad (24)$$

$$q_{ch,pk} = prf * q_{ch} \quad (25)$$

Onde: A_{ch} é a área seccional de vazão do canal (m^2); $q_{ch,pk}$ é a vazão de pico (m^3/s), prf é o fator de ajuste da taxa de pico; q_{ch} é a vazão média do canal (m^3/s).

A máxima quantidade de sedimentos que pode ser transportada pelo canal é calculada pela equação 26 (BAGNOLD, 1977):

$$conc_{sed,ch,mx} = c_{sp} \cdot v_{ch,pk}^{spexp} \quad (26)$$

Onde: $conc_{sed,ch,mx}$ é a concentração máxima de sedimentos que pode ser transportada pela água (ton/m^3 ou Kg/L); c_{sp} é o coeficiente definido pelo usuário; $v_{ch,pk}$ é a velocidade de pico no canal (m/s) e; $spexp$ é um expoente definido pelo usuário que, geralmente, varia entre 1 e 2, sendo comumente definido como 1,5 (ARNOLD et al., 1995).

Quando a concentração de sedimentos no canal, no início do passo de tempo, é maior que a quantidade máxima de sedimentos calculada, ocorre o processo de deposição, determinado pela equação 27 (NEITSCH et al., 2011):

$$S_{dep} = (coc_{sed,ch,i} - conc_{sed,ch,mx}) V_{ch} \quad (27)$$

Onde: S_{dep} é a quantidade de sedimentos depositada no canal (ton), $conc_{sed,ch,i}$ é a concentração inicial de sedimentos no canal ($ton.m^{-3}$), $conc_{sed,ch,mx}$ é a concentração máxima de sedimentos que pode ser transportada pela água ($ton.m^{-3}$), e V_{ch} é o volume de água no canal (m^3).

Quando a concentração de sedimentos no canal, no início do passo de tempo, é menor que a quantidade máxima de sedimentos calculada, a degradação passa a ser o processo dominante, sendo calculada pela equação 28 (NEITSCH et al., 2011):

$$S_{deg} = (conc_{sed, ch, mx} - conc_{sed, ch, i}) V_{ch} \cdot K_{ch} \cdot C_{ch} \quad (28)$$

Onde: S_{deg} é a quantidade de sedimentos reentrando no canal (ton), K_{ch} é o fator de erodibilidade do canal ($cmh^{-1}Pa$), e C_{ch} é o fator de cobertura do canal. Os dois últimos correspondem, respectivamente, aos parâmetros CH_EROD e CH_COV do modelo SWAT.

Uma vez calculada a degradação e a deposição no canal, a quantidade final de sedimentos no canal é dada pela equação 29 (NEITSCH et al., 2011):

$$sed_{ch} = sed_{ch, i} - sed_{dep} + sed_{deg} \quad (29)$$

Onde: sed_{ch} é a quantidade de sedimentos suspensos no canal (ton); $sed_{ch, i}$ é a quantidade de sedimentos suspensos que chega ao canal no início do período de tempo (ton); sed_{dep} é a quantidade de sedimento depositada no canal (ton); sed_{deg} é a quantidade de sedimento oriundo da degradação do canal (ton).

A quantidade de sedimentos que deixa o canal é dada pela equação 30 (NEITSCH et al., 2011).

$$sed_{out} = sed_{ch} \cdot \frac{V_{out}}{V_{ch}} \quad (30)$$

Onde: sed_{out} é a quantidade de sedimentos que deixa o canal (ton) e; V_{ch} é o volume de água no canal (m^3).

APÊNDICES

APÊNDICE A: DESCRIÇÃO DE ESTUDOS QUE UTILIZARAM RNAs PARA CÁLCULOS HIDROSSEDIMENTÓGICOS

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continua)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ Nº de registros	Intervalo de tempo	NS/R ² /R	Outras observações/conclusões
Jain (2001)	2 estações no rio Mississippi (Chester e Thebes)	Chester: 1835276 km ² Thebes: 1847190 km ²	desenvolver curvas chave nível d'água-vazão-sedimentos em duas estações	feedforward (3 camadas)	retropropagativo (Gradiente de Descida)	nível de água (H); concentração de sedimentos (S) cenários: 1) H _t , H _{t-1} , Q _{t-1} e S _{t-1} ; 2) H _t , H _{t-1} , H _{t-2} , Q _{t-1} e S _{t-1} ; 3) H _t , H _{t-1} , H _{t-2} , Q _{t-1} , Q _{t-2} e S _{t-1} ; 4) H _t , H _{t-1} , H _{t-2} , Q _{t-1} , Q _{t-2} , S _{t-1} e S _{t-2} ; 5) H _t , H _{t-1} , Q _{t-1} , Q _{t-2} , S _{t-1} e S _{t-2}	vazão (Q _t) e concentração de sedimentos (S _t)	Chester: 25/12/1985-31/08/1987 (treinamento) e 01/09/1986-31/01/1987 (verificação) Thebes: 01/01/1990-30/09/1990 (treinamento) e 15/01/1991-10/08/1991 (verificação)	diário	Chester: a) treinamento- R=0,997; 0,998; 0,997; 0,996 e 0,998 para Q e R=0,954; 0,963; 0,959; 0,968 e 0,960 para S, considerando os cenários 1, 2, 3, 4 e 5; b) verificação- R=0,975; 0,988; 0,966; 0,964 e 0,973 para Q e R=0,863; 0,839; 0,759; 0,826 e 0,869 para S, considerando os cenários 1, 2, 3, 4 e 5 Thebes: a) treinamento- R=0,994; 0,993; 0,993; 0,993 e 0,993 para Q e R=0,929; 0,931; 0,946; 0,954 e 0,961 para S, considerando os cenários 1, 2, 3, 4 e 5; b) verificação- R=0,994; 0,994; 0,995; 0,991 e 0,992 para Q e R=0,916; 0,916; 0,926; 0,912 e 0,909 para S, considerando os cenários 1, 2, 3, 4 e 5	em geral: melhores resultados para combinação cenário 5)
Yitian e Gu (2003)	Jingjiang, um afluente do rio Yangtze e lago Dongting, província de Hunan, China	-	desenvolver uma RNA para simular a vazão e o transporte de sedimentos em um sistema de rios	RNA feedforward (3 camadas)	retropropagativo (Gradiente de Descida)	vazão e carga de sedimentos nos rios à montante. Foram introduzidos no modelo RNA as equações de princípio e conservação das massas	vazão e carga de sedimentos à jusante	1956-1979 para treinamento e 1980-1988 para verificação	anual	R ² =0,997 no treinamento e R ² =0,986 para verificação	
Cigizoglu (2004)	bacia do rio Schuylkill, Philadelphia (2 estações)	1830 km ² à jusante e 355 km ² à montante	2 aplicações: i) previsão dos sedimentos em suspensão na jusante (1 dia à frente), utilizando como entrada dados de sedimentos à jusante (FI) e à montante (FII), separadamente; ii) estimativa dos sedimentos a jusante usando dados de fluxo à jusante (EI) e à montante (EII)	perceptron de múltiplas camadas (3 camadas)	retropropagativo (Marquardt)	FI (dados jusante): testados - i) S _{t-1} ; S _{t-2} ; S _{t-3} e S _{t-4} , periodicidade (dia do ano) e ii) Q _{t-1} , Q _{t-2} , Q _{t-3} , Q _{t-4} , Q _{t-5} , Q _{t-6} , Q _{t-7} , Q _{t-8} , Q _{t-9} e Q _{t-10} FII (dados montante): testados - i) S _t , S _{t-1} , S _{t-2} , S _{t-3} , S _{t-4} , S _{t-5} , S _{t-6} , S _{t-7} , S _{t-8} e S _{t-9} e periodicidade EI: Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3} e Q _{t-4} e periodicidade EII: Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3} , Q _{t-4} , Q _{t-5} , Q _{t-6} , Q _{t-7} , Q _{t-8} , Q _{t-9} e componente de periodicidade	S _t à jusante	29 anos: 01/10/1952-30/09/1981 treinamento: 18.10.1952-21.10.1978 (FI); 18.10.1952-21.10.1978 (FII); 18.10.1952-21.10.1978 (EI) e 18.10.1952-21.10.1978 (EII) verificação: 22.10.1978-17.09.1981 (FI); 22.10.1978-17.09.1981 (FII); 22.10.1978-17.09.1981 (EI) e 22.10.1978-17.09.1981 (EII)	diário	Resultados comparados aqueles obtidos por curva-chave tradicional e por análise de regressão. resultados da verificação: R ² = 0,27 (FI-i) e 0,51 (FI-ii) R ² =0,5 (FII-ii); 0,91 (EI) e 0,84 (EII)	
Kisi (2005)	2 estações (rio Valenciano e Quebrada Blanca), Porto Rico	Valenciano: 43,57 km ² Quebrada Blanca: 863 km ²	investigar a relação vazão-sedimentos suspensos	testados modelos Neuro-Fuzzi, RNAs (feedforward 3 camadas), análises de regressão e curva-chave tradicional	retropropagativo (Gradiente de Descida) para RNA	vazão (Q) e CSS cenários: i) Q _t ; ii) Q _t e Q _{t-1} ; iii) Q _t e CSS _{t-1} ; iv) Q _t , Q _{t-1} e CSS _{t-1}	CSS _t	1994 para treinamento e 1995 para verificação		Valenciano: R ² =0,867; 0,874; 0,702 e 0,876 para cenários i), ii), iii) e iv) e por Quebrada Blanca: R ² =0,821; 0,865; 0,754 e 0,888 para cenários i), ii), iii) e iv)	configurações RNA: a) Valenciano: 1-1-1; 2-2-1; 2-2-1 e 3-2-1 para cenários i), ii), iii) e iv); b) Quebrada Blanca: 1-2-1; 2-2-1; 2-2-1 e 3-2-1 para cenários i), ii), iii) e iv);
Sarangi et al. (2005)	sub-bacia de St. Esprit, Quebec, Canadá	26,1 km ²	relacionar parâmetros geomorfológicos (representativos da hidrologia da superfície) às características da precipitação para prever a vazão de pico e as perdas de sedimentos	RNA feedforward (3 camadas) e análises de regressão	retropropagativo (Gradiente de Descida)	precipitação (P) e parâmetros geomorfológicos que descrevem as características de drenagem e o comportamento do fluxo de água na superfície cenários: 1) RNA sem parâmetros geomorfológicos: duração e volume precipitado; 2) entradas do cenário "1" associadas aos parâmetros geomorfológicos adimensionais	vazão de pico e perda de sedimentos	abril a setembro entre 1994 e 1997: 64 eventos, dos quais: 50% (32 valores) usados para treinamento, 25% (16 valores) para validação cruzada e 25% (16 dados) para verificação Foram testadas 20 combinações diferentes desses dados para a verificação das RNAs		verificação: a) RNA sem parâmetros geomorfológicos (2-8-1): R ² variou entre 0,69 e 0,76 para vazão de pico e R ² variou entre 0,68 e 0,76 e NS entre 0,59 e 0,68 para sedimentos; b) RNA com parâmetros geomorfológicos (6-8-1): R ² variou entre 0,78 e 0,95 e NS entre 0,71 e 0,82 para vazão de pico e R ² variou entre 0,75 e 0,93 e NS entre 0,65 e 0,76 para perda de sedimentos # melhor modelo RNA (base geomorfológica - R ² =0,95 e NS=0,82) aplicado aos 64 eventos para previsão da vazão de pico: R ² =0,83 e NS=0,61	introdução dos parâmetros geomorfológicos melhora o desempenho dos modelos RNA. Resultados dos modelos RNAs são superiores aos das análises de regressão
Agarwal et al. (2006)	bacia do rio Vamsadhara (Índia)	7820 km ²	desenvolver modelo baseado em RNA para simulação do escoamento e sedimentos (diário, semanal, 10 dias e mensal)	feedforward (3 camadas)	algoritmo retropropagativo (Gradiente de Descida), com aprendizado no modo padrão e no modo batch. Parada do treinamento por: i) menor erro no treinamento e validação cruzada; ii) 5000 interações	dados diários de precipitação e escoamento	produção de sedimentos	calibração: período de monções (01/06 a 31/10 de 1984-1987) validação cruzada: 1988-1989 verificação: 1992-1995	diário, semanal, 10 dias e mensal	Batch (menor erro): NS=0,75 (diário); 0,78 (semanal); 0,83 (10 dias) e 0,91 (mensal) na calibração; NS=0,16 (diário); 0,12 (semanal); 0,54 (10 dias) e 0,83 (mensal) na validação cruzada Batch (5000 interações): NS=0,56 (diário); 0,61 (semanal); 0,80 (10 dias) e 0,83 (mensal) na calibração; NS=0,06 (diário); -0,37 (semanal); 0,40 (10 dias) e 0,73 (mensal) na validação cruzada Padrão (menor erro): NS=0,72 (diário); 0,78 (semanal); 0,83 (10 dias) e 0,92 (mensal) na calibração; NS=0,63 (diário); 0,64 (semanal); 0,68 (10 dias) e 0,79 (mensal) na validação cruzada e NS=0,68 (diário); 0,52 (semanal); 0,41 (10 dias) e 0,54 (mensal) na verificação Padrão (5000 interações): NS=0,87 (diário); 0,86 (semanal); 0,90 (10 dias) e 0,92 (mensal) na calibração; NS=0,59 (diário); 0,47 (semanal); 0,63 (10 dias) e 0,77 (mensal) na validação cruzada	melhor resultado RNA treinamento pelo modo padrão (menor erro treinamento e validação cruzada)
Cigizoglu e Alp (2006)	bacia do rio Juniata, Pennsylvania	-	estimar a quantidade diária de sedimentos suspensos	feedforward (3 camadas) e Rede Neural de Regressão Generalizada (GRNN)	retropropagativo (Levenberg-Marquardt) para a RNA feedforward	vazão (Q) e sedimentos suspensos (S) testados: 1) Q _t ; 2) Q _t e Q _{t-1} ; 3) Q _t , Q _{t-1} e Q _{t-2} ; 4) Q _t , Q _{t-1} , Q _{t-2} e Q _{t-3} ; 5) Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3} e Q _{t-4} ; 6) Q _t , Q _{t-1} , Q _{t-2} e S _{t-1}	sedimentos suspensos (S _t)	1983-89. treinamento= 01.01.1983-22.06.1988 verificação: 23.06.1988- 07.06.1989	diário	R ² (verificação)= 0,880; 0,898; 0,958; 0,943; 0,931 e 0,953 para as situações 1, 2, 3, 4, 5 e 6 da RNA feedforward e 0,942 para a rede GRNN(3;0,02;1)	RNA feedforward: melhor resultado combinação 4 (entradas)
Cigizoglu e Kisi (2006)	bacia do rio Schuylkill (estação Manayunk), EUA	-	estimar quantidade diária de sedimentos suspensos	RNA (feedforward 3 camadas) e range-dependent neural network (RDNN)	retropropagativo (Levenberg-Marquardt) para RNA feedforward	vazão (Q) e quantidade de sedimentos suspensos (S) testados: 1) Q _t ; 2) Q _t e S _{t-1} ; 3) Q _t , Q _{t-1} e S _{t-1} ; 4) Q _t , Q _{t-1} , S _{t-1} e S _{t-2}	quantidade de sedimentos suspensos	8760 para treinamento (01/10/1952-30/09/1976) e 1725 para verificação (01/10/1976-30/09/1981). Dados treinamento também foram divididos em 3 grupos: grupo i) 2920 (01/10/1952-30/09/1960); grupo ii) 2920 (01/10/1960-30/09/1968); grupo iii) 2920 (01/10/1968-30/09/1976)	diário	feedforward - resultados verificação NS (1 entrada: Q _t)= 0,791 para treinamento com grupo i); 0,564 para grupo ii); 0,749 para grupo iii) e 0,854 para todos os dados de treinamento NS (2 entradas: Q _t e S _{t-1})=0,829 para grupo i); 0,735 para grupo ii); 0,849 para grupo iii) e 0,784 para todos os dados de treinamento	em geral: os NS da RDNN para uma entrada são melhores do que para a RNA feedforward, enquanto que para 2 entradas são piores. EaM são menores para a RDNN

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ Nº de registros	Intervalo de tempo	NS/R ² /R	Outras observações/conclusões
Raghuwanshi, Singh e Reddy (2006)	bacia de Nagwan, distrito de Jharkhand, Índia	92,46 km ²	desenvolver modelos RNA para estimativa da vazão e produção de sedimentos diária e semanal	RNA (feedforward-testadas 3 e 4 camadas)	retropropagativo (Levenberg-Marquardt)	precipitação (P) e temperatura (T) cenários: 3 para saída diária (1 a 3) e 2 semanal (4 a 5), 1) T _i ; 2) P _i e P _{i-1} ; 3) P _i ; P _{i-1} ; T _{max} e T _{min} ; 4) P _i e P _{i-1} ; T _{max} e T _{min}	vazão diária (Q _i) e semanal (Q _s) e produção de sedimentos diária (S _i) e semanal (S _s)	treinamento: a) diário: 765 dados dos meses de junho a outubro - 5 anos (1991-1995); b) semanal: 110 dados verificação: a) diário: 306 dados dos meses de junho a outubro - 2 anos (1996-1997); b) semanal: 44 dados	diário (3 modelos) e semanal (2 modelos)	diário: NS variou entre 0,506 (1-5-2) e 0,978 (4-18-18-2) para vazão e NS variou entre 0,525 (1-5-2) e 0,978 (4-18-18-2) melhores modelos diário: a) vazão: NS=0,795 (1-18-18-2); NS=0,935 (2-18-18-2) e NS=0,978 (4-18-18-2) no treinamento e; NS=0,709; 0,869 e 0,974 na verificação; b) sedimentos: NS=0,789 (4-18-18-2); NS=0,978 (2-18-18-2) e NS=0,978 (4-18-18-2) no treinamento e NS=0,640; 0,868 e 0,980 na verificação melhores modelos semanal: a) vazão: NS=0,982 (1-18-18-2) e NS=0,995 (3-18-18-2) no treinamento e; NS=0,959 e 0,976 na verificação; b) sedimentos: NS=0,987 (1-18-18-2) e NS=0,996 (3-18-18-2) no treinamento e; NS=0,924 e 0,984 na verificação	-
Alp e Cigizoglu (2007)	bacia do rio Juniata (Pennsylvania)	-	estimar a carga de sedimentos diária	2 RNAs (3 camadas): RNA feedforward e RNA de base radial	retropropagativo (Levenberg-Marquardt) para RNA feedforward	dados diários: i) precipitação (P); ii) vazão (Q); iii) precipitação + vazão => testadas 3 simulações e até 5 tipos de combinação dos dados simulação (i): 1) P _i ; 2) P _i , P _{i-1} ; 3) P _i , P _{i-1} , P _{i-2} ; 4) P _i , P _{i-1} , P _{i-2} , P _{i-3} ; 5) P _i , P _{i-1} , P _{i-2} , P _{i-3} , P _{i-4} simulação (ii): 1) P _i ; 2) P _i , P _{i-1} ; 3) P _i , P _{i-1} , P _{i-2} ; 4) P _i , P _{i-1} , P _{i-2} , P _{i-3} ; 5) P _i , P _{i-1} , P _{i-2} , P _{i-3} , P _{i-4} simulação (iii): 1) P _i , P _{i-1} , P _{i-2} , Q _i ; 2) P _i , P _{i-1} , P _{i-2} , Q _i , Q _{i-1} ; 3) P _i , P _{i-1} , Q _i , Q _{i-1} ; 5) P _i , P _{i-1} , Q _i , Q _{i-1}	carga de sedimento diária	1500 para treinamento e 500 verificação treinamento: 01/01/1983-22/06/1988 verificação: 23/06/1988-07/06/1989	diário	simulação (i): R ² =0,018; 0,098; 0,136; 0,213; 0,120 para combinações 1); 2); 3); 4) e 5) para RNA feedforward e R ² =0,025; 0,095; 0,150; 0,174 e 0,159 para as combinações 1), 2), 3), 4) e 5) da RNA de base radial simulação (ii): R ² =0,813; 0,827; 0,873; 0,864; 0,861 para combinações 1), 2), 3), 4) e 5) para RNA feedforward e R ² =0,819; 0,836; 0,878; 0,869 e 0,870 para as combinações 1), 2), 3), 4) e 5) da RNA de base radial simulação (iii): R ² =0,871; 0,870; 0,786 e 0,897 para as combinações 1), 2), 3) e 4) para RNA feedforward e R ² =0,913; 0,905; 0,889 e 0,921 para as combinações 1), 2), 3) e 4) da RNA de base radial Resultados obtidos para a verificação das redes	melhores resultados: simulação (i)=combinação 4); simulação (ii) = combinação 3) e simulação (iii)= combinação 4) RNA de base radial: desempenho levemente melhor
Ardıçlıoğlu, Kisi e Haktınar (2007)	Bacias dos rios Göynük (estação Çaygazi) e Murat (estação Palu), Turquia	2232 e 25447 km ² para as estações Çaygazi e Palu, respectivamente	prever a produção mensal de sedimentos suspensos	feedforward (3 camadas)	retropropagativo: Levenberg-Marquardt (LM) e Gradiente de Descida (GD)	dados mensais de vazão (Q) e concentração de sedimentos suspensos (CSS). Çaygazi (índice "c"): 1) Q _i ; 2) Q _i e α (periodicidade) Palu (índice "p"): 1) Q _i ; 2) Q _i e α Palu a partir de Çaygazi: 1) Q _i ; 2) Q _i e α; 3) Q _i e S _i ; 4) Q _i , S _i e α; 5) Q _i , S _i e Q _p ; 6) Q _i , S _i , Q _p e α	CSS _i em Çaygazi e Palu e CSS _i em Palu a partir de dados de Çaygazi	74 meses para treinamento e 18 para verificação	mensal	Çaygazi: R ² =0,758 (situações 1 e 2) para verificação do treinamento realizado com LM e R ² =0,761 e 0,775 (para situações 1 e 2) para verificação do treinamento realizado com GD Palu: R ² =0,805 e 0,830 (situações 1 e 2) para verificação treinamento realizado com LM e R ² =0,806 e 0,832 (situações 1 e 2) para treinamento realizado com GD Palu a partir de Çaygazi: R ² =0,919; 0,889; 0,876; 0,8847; 0,870 e 0,902 para as combinações 1, 2, 3, 4, 5 e 6 (algoritmo LM) e R ² =0,782; 0,781; 0,800; 0,787; 0,796 e 0,738 para as combinações 1, 2, 3, 4, 5 e 6 (algoritmo GD)	Çaygazi e Palu: melhores resultados de CSS para treinamento com algoritmo LM, usando (Q _i e α) e Q _p , respectivamente Palu a partir Çaygazi: melhor resultado de CSS para treinamento com algoritmo LM, usando Q _c
Kisi (2007)	2 estações (Calleguas e Santa Clara)	Calleguas=659 km ² Santa Clara=1660 km ²	estimativa dos sedimentos em suspensão	range-dependent neural networks (RDNN); RNA (feedforward 3 camadas); regressão linear; curva-chave tradicional; range-dependent linear regression (RDLR) e; curva-chave (RDSRC)	Levenberg-Marquardt para RNA feedforward	vazão (Q) e sedimentos suspensos (S) cenários: 1) Q _i ; 2) Q _i e Q _{i-1} ; 3) Q _i e S _{i-1} ; 4) Q _i , Q _{i-1} e S _{i-1}	sedimentos suspensos (S _i)	10 anos (1969-1978): 8 anos (1969-1976) para treinamento e 2 anos (1977-1978) para verificação	diário	estatísticas verificação: Calleguas: 0,945; 0,960; 0,955 e 0,958 para RNA cenários 1, 2, 3 e 4. R ² = 0,959 para RDNN Santa Clara: 0,844; 0,836; 0,822 e 0,883 para RNA cenários 1, 2, 3 e 4. R ² =0,891 para RDNN	foco principal é comparar resultados obtido pelo modelo RDNN com os demais. a) Calleguas: configurações 1-1-1; 2-2-1; 2-3-1 e 3-4-1 para cenários 1, 2, 3 e 4. Melhor RNA cenário 2. Curva-chave tradicional teve melhor R ² (0,985), menores erros (RMSE e Eam) para RDNN Santa Clara: configurações 1-1-1; 2-2-1; 2-2-1 e 3-3-1 para cenários 1, 2, 3 e 4. Melhor RNA cenário 4. Melhor R ² (0,906) para RDLR, menores erros RDNN
Zhu, Lu e Zhou (2007)	estação Huangguayuan, rio Longchuanjiang, China	5560 km ²	simular o fluxo de sedimentos suspensos mensal	perceptron de múltiplas camadas (3 camadas)	retropropagativo (Gradiente de Descida)	dados mensais médios: precipitação (P), temperatura (T), intensidade dos eventos (P ₂₅ - P acumulada ≥25 mm por dia no mês e; P ₅₀ - P acumulada ≥ 50 mm por dia no mês) e vazão (Q) cenários: 1) P _i e T _i ; 2) T _i , P _i , T _{i-1} e P _{i-1} ; 3) P _i , T _i , P _{i-1} , T _{i-1} , P _{i-2} e T _{i-2} ; 4) P _i , T _i , P _{i-1} , T _{i-1} , P _{i-2} , T _{i-2} , P _{i-3} e T _{i-3} ; 5) T _i , P _i , P _{25i} , P _{50i} ; 6) T _i , P _i , P _{25i} , P _{50i} , T _{i-1} e P _{i-1} ; 7) T _i , P _i , P _{25i} , P _{50i} , T _{i-1} , P _{i-1} , T _{i-2} e P _{i-2} ; 8) T _i , P _i , P _{25i} , P _{50i} , T _{i-1} , P _{i-1} , T _{i-2} , T _{i-3} e P _{i-3} ; 9) T _i , P _i e Q _i ; 10) T _i , P _i e Q _i , T _{i-1} , P _{i-1} e Q _{i-1} ; 11) T _i , P _i e Q _i , T _{i-1} , P _{i-1} , Q _{i-1} , T _{i-2} , P _{i-2} e Q _{i-2} ; 12) T _i , P _i e Q _i , T _{i-1} , P _{i-1} , Q _{i-1} , T _{i-2} , P _{i-2} , Q _{i-2} , T _{i-3} , P _{i-3} e Q _{i-3} ; 13) Q _i e Q _{i-1} ; 14) Q _i e Q _{i-1} ; 15) Q _i , Q _{i-1} e Q _{i-2} ; 16) Q _i , Q _{i-1} , Q _{i-2} e Q _{i-3}	descarga de sedimentos suspensos (Q _s)	36 anos: 1960, 1963, 1965-1966 e 1970-2001, sendo 128 dados para treinamento, 40 para validação cruzada e 120 para verificação	mensal	a) treinamento: R ² =0,66; 0,767; 0,769; 0,770; 0,680; 0,790; 0,793; 0,793; 0,817; 0,834; 0,838; 0,848; 0,696; 0,767; 0,803 e 0,806 para cenários 1 a 16, b) validação cruzada: R ² =0,541; 0,729; 0,713; 0,717; 0,524; 0,732; 0,725; 0,720; 0,817; 0,808; 0,818; 0,813; 0,716; 0,714; 0,804 e 0,06 para cenários 1 a 16; c) verificação: R ² =0,663; 0,765; 0,746; 0,755; 0,706; 0,800; 0,778; 0,784; 0,893; 0,888; 0,871; 0,864; 0,836; 0,882; 0,857 e 0,865 para cenários 1 a 16	cenários baseados apenas na precipitação e temperatura mostraram os resultados mais pobres em relação aos demais modelos
Kisi (2008)	2 estações (rio Valenciano e Quebrada Blanca), Porto Rico	Valenciano: 43,57 km ² Quebrada Blanca: 863 km ²	estimativa dos sedimentos em suspensão	feedforward (3 camadas)	Levenberg-Marquardt, Gradiente Conjugado e Gradiente de Descida	foram testadas como entrada diversas combinações de valores antecedentes de vazão e concentração de sedimentos	CSS _i	01/10/1993-30/09/1994 para treinamento e 01/10/1994-30/09/1995 para verificação	diário	Quebrada Blanca: a) treinamento: R ² =0,964; 0,937 e 0,893 para Levenberg-Marquardt, gradiente conjugado e gradiente descendente; b) verificação: R ² =0,940; 0,896 e 0,704 para Levenberg-Marquardt, gradiente conjugado e gradiente descendente Rio Valenciano: a) treinamento: R ² =0,627; 0,600 e 0,517 para Levenberg-Marquardt, gradiente conjugado e gradiente descendente; b) verificação: R ² =0,869; 0,846 e 0,751 para 3 para Levenberg-Marquardt, gradiente conjugado e gradiente descendente	Quebrada Blanca: Levenberg-Marquardt teve melhor R ² e menor erro Rio Valenciano: melhor R ² para Levenberg-Marquardt, mas menor erro para gradiente conjugado
Hamidi e Kayaalp (2008)	bacia do rio Tigris, Turquia	5655,2 km ²	estabelecer relações entre quantidade de sedimentos e parâmetros hidrológicos	RNA (feedforward 3 camadas) e ajustes por regressão	retropagativo (Gradiente de Descida)	precipitação média mensal (P), temperatura do ar (T), vazão (Q). Entradas: 1) P; 2) T; 3) Q; 4) P e T; 5) P e Q; 6) T e Q; 7) P, T e Q	sedimentos suspensos (S _i)	329 dados mensais: 165 usados para treinamento, 82 para validação cruzada e 82 para verificação	mensal	treinamento: R= 0,16; 0,18; 0,97; 0,19; 0,97; 0,95; 0,97 para as entradas 1, 2, 3, 4, 5, 6 e 7 verificação: R=0,16; 0,26; 0,95; 0,24; 0,92; 0,94 e 0,90 para as entradas 1, 2, 3, 4, 5, 6 e 7	melhor modelo tem como entrada P e Q

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ Nº de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Jain (2008)	2 estações no rio Mississippi (Chester e Thebes) e 1 em Conococheague Creek	Chester: 1835276 km² Thebes: 1847190 km² Conococheague Creek: 126464 km²	modelar a relação nível d'água-vazão-concentração de sedimentos através de redes neurais compostas (RNAC). Objetivo foco: analisar a capacidade da RNAC prever sedimentos suspensos	2 RNAs feedforward (3 camadas) - uma para determinação da vazão e outra para sedimentos	retropropagativo (Gradiente de Descida)	nível de água; concentração de sedimentos (S) cenários (Chester e Thebes): 1) H_t, H_{t-1} e Q_{t-1} ; 2) H_t, H_{t-1}, Q_{t-1} e S_{t-1} ; 3) $H_t, H_{t-1}, H_{t-2}, Q_{t-1}$ e S_{t-1} ; 4) $H_t, H_{t-1}, H_{t-2}, Q_{t-1}, Q_{t-2}$ e S_{t-1} ; 5) $H_t, H_{t-1}, Q_{t-1}, Q_{t-2}, S_{t-1}$ e S_{t-2} cenários Conococheague Creek: 1) H_t, Q_{t-1} e S_{t-1} ; 2) H_t, H_{t-1}, Q_{t-1} e S_{t-1} ; 3) $H_t, H_{t-1}, H_{t-2}, Q_{t-1}$ e S_{t-1}	vazão (Q) e concentração de sedimentos (S)	Chester: 25/12/1985-31/08/1987 (treinamento) e 01/09/1986-31/01/1987 (verificação) Thebes: 01/01/1990-30/09/1990 (treinamento) e 15/01/1991-10/08/1991 (verificação) Conococheague Creek: 01/09/1974-31/08/1975 (treinamento) e 01/09/1975-22/12/1976 (verificação)	diário	Chester: a) treinamento- R=0,997; 0,999; 0,998; 0,998 e 0,998 para Q e R=0,959; 0,959; 0,963; 0,958 e 0,967 para S, considerando os cenários 1, 2, 3, 4 e 5; b) verificação- R=0,994; 0,985; 0,979; 0,985 e 0,985 para Q e R=0,802; 0,831; 0,806; 0,801 e 0,874 para S, considerando os cenários 1, 2, 3, 4 e 5 Thebes: a) treinamento- R=0,996; 0,998; 0,998; 0,997 e 0,997 para Q e R=0,959; 0,936; 0,939; 0,934 e 0,943 para S, considerando os cenários 1, 2, 3, 4 e 5; b) verificação- R=0,982; 0,997; 0,993; 0,996 e 0,997 para Q e R=0,912; 0,924; 0,923; 0,924 e 0,912 para S, considerando os cenários 1, 2, 3, 4 e 5 Conococheague Creek: a) treinamento- R=0,995; 0,993 e 0,997 para Q e R=0,752; 0,759 e 0,765 para S, considerando os cenários 1, 2 e 3; b) verificação- R=0,932; 0,989 e 0,974 para Q e R=0,627; 0,623 e 0,648 para S, considerando os cenários 1, 2 e 3	
Partral e Cigizoglu (2008)	e estações (montante e jusante) no rio Schuylkill, Filadélfia, Pensilvânia, EUA	-	produção diária de sedimentos suspensos. Situações: 1) sedimentos a jusante determinado a partir de dados anteriores (sedimentos) à jusante (C1) ou montante (C2); 2) sedimentos à jusante determinados por dados (vazão) à jusante (C3) ou à montante (C4) e 3) vazão à jusante determinado por vazão à montante	RNA (feedforward - 3 camadas) e RNA associada a transformada Wavelet (RNA Wavelet)	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão (Q) e carga de sedimentos (S). Para a RNA Wavelet os dados foram decompostos (w: 1 a 10) Situações: 1) C1: a) RNA: $S_{t-1}; S_{t-2}; S_{t-3}$ e S_{t-4} ; b) RNA Wavelet: $S_{wt-1}; S_{wt-2}; S_{wt-3}; S_{wt-4}; S_{wt-5}; S_{wt-6}$ e S_{wt-7} 2) C2: a) RNA: $S_{t-1}; S_{t-2}; S_{t-3}; S_{t-4}; S_{t-5}$ e S_{t-6} ; b) RNA Wavelet: $S_{wt-1}; S_{wt-2}; S_{wt-3}; S_{wt-4}; S_{wt-5}; S_{wt-6}$ e S_{wt-7} 3) C3: a) RNA: $Q_t; Q_{t-1}; Q_{t-2}; Q_{t-3}; Q_{t-4}; Q_{t-5}; Q_{t-6}$ e Q_{t-7} ; b) RNA Wavelet: $Q_{wt-1}; Q_{wt-2}; Q_{wt-3}; Q_{wt-4}; Q_{wt-5}; Q_{wt-6}$ e Q_{wt-7} 4) C4: RNA: $Q_t; Q_{t-1}; Q_{t-2}; Q_{t-3}; Q_{t-4}$ e Q_{t-5} ; b) RNA Wavelet: $Q_{wt-1}; Q_{wt-2}; Q_{wt-3}; Q_{wt-4}; Q_{wt-5}; Q_{wt-6}; Q_{wt-7}; Q_{wt-8}$ e Q_{wt-9} 5) C5: a) RNA: $Q_{t-1}; Q_{t-2}; Q_{t-3}; Q_{t-4}; Q_{t-5}; Q_{t-6}$ e Q_{t-7} ; b) RNA Wavelet: $Q_{wt-1}; Q_{wt-2}; Q_{wt-3}; Q_{wt-4}; Q_{wt-5}$ e Q_{wt-6}	carga de sedimentos suspensos à jusante e um modelo para vazão à jusante	50 anos: 01/10/1952-30/09/1981 treinamento/validação: 9517 valores ou 90% dos dados) - 01/09/1952 a 21/10/1978. Desse total, 7138 dados para treinamento e 2379 para validação cruzada verificação: 1060 valores ou 10% da série - 21/10/1978 a 17/09/1981	diário	resultados na verificação RNA (feedforward): R²=0,18 (4-4-10) para situação C1; R²=0,50 (6-4-1) para situação C2; R²=0,89 (7-4-1) para situação C3; R²=0,79 (5-4-1) para situação C4 e R²=0,57 (7-3-1) para situação C5 RNA Wavelet: R²=0,74 (7-4-1) para situação C1; R²=0,50 para situação C2; R²=0,397 (9-4-1) para situação C3; R²=0,92 (9-4-1) para situação C4 e R²=0,71 (6-4-1) para situação C5	
Rai e Mathur (2008)	2 bacias hidrográficas: i) W2 na bacia de Treynor (Iowa, EUA) e; ii) sub-bacia W7, na bacia experimental de Goodwin Creek (Mississippi, EUA)	W2=0,335 km² W7=1,6 km²	analisar a relação precipitação-vazão-sedimentos, por evento	feedforward (3 camadas)	retropropagativo (Gradiente de Descida) com regularização Bayesiana	precipitação (P), vazão (Q) e fluxo de sedimentos (S) W2: a) para estimar Q: 1) P_{t-1}, P_t e Q_{t-1} ; 2) P_{t-1}, P_t e $Q_{t-1}, Q_{t-2}, Q_{t-3}$ e S_{t-1} ; 3) P_{t-1}, P_t e $Q_{t-1}, Q_{t-2}, Q_{t-3}$ e S_{t-1} W7: a) para estimar Q: 1) P_{t-1}, P_t e Q_{t-1} ; 2) $P_{t-1}, P_t, Q_{t-1}, Q_{t-2}, S_{t-1}$ e S_{t-2} ; 3) $P_{t-1}, P_t, Q_{t-1}, Q_{t-2}, S_{t-1}$ e Q_{t-2} b) para estimar S: 1) $P_{t-1}, P_t, Q_{t-1}, Q_{t-2}, S_{t-1}$ e S_{t-2} ; 2) $P_{t-1}, P_t, Q_{t-1}, Q_{t-2}, S_{t-1}$ e Q_{t-2} ; 3) $P_{t-1}, P_t, Q_{t-1}, Q_{t-2}, S_{t-1}$ e Q_{t-2}	vazão (Q) e fluxo de sedimentos (S)	22 eventos analisados: 70% para treinamento e 30% para verificação	diário	W2: a) vazão: i) treinamento: R=NS=0,99 e 0,99 para cenário 1 e configurações 3-3-1 e 3-6-1; R=NS=0,99 para cenário 2 (3-3-1); R=0,89 e NS=0,79 para cenário 3 (3-3-1); ii) verificação: R=0,99 e 0,79 e NS=0,98 e -0,93 para cenário 1 e configurações 3-3-1 e 3-6-1; R=0,99 e NS=0,98 para cenário 2 (3-3-1); R=0,87 e NS=0,75 para cenário 3 (3-3-1); b) sedimentos: i) treinamento: R=NS=0,99 e 0,99 para cenário 1 e configurações 7-7-1 e 7-14-1; R=NS=0,99 para cenário 2 e configurações 6-6-1 e 6-12-1; R=0,94 e 0,93 e NS=0,88 e 0,87 para cenário 3 e configurações 3-3-1 e 3-4-1; R=NS=0,99 para cenário 4 e configurações 3-6-1 e 3-9-1; ii) verificação: R=0,96 e 0,67 e NS=0,90 e -0,82 para cenário 1 e configurações 7-7-1 e 7-14-1; R=0,82 e 0,83 e NS=0,64 e -0,97 para cenário 2 e configurações 6-6-1 e 6-12-1; R=0,76 e 0,85 e NS=0,50 e 0,71 para cenário 3 e configurações 3-3-1 e 3-4-1; R=0,85 e 0,89 e NS=0,72 e 0,78 para cenário 4 e configurações 3-6-1 e 3-9-1 W7: a) vazão: i) treinamento: R=NS=0,99 e 1,00 para cenário 1 e configurações 3-3-1 e 3-6-1; R=NS=0,99 para cenário 2 (3-3-1); R=0,94 e 0,95 e NS=0,90 e 0,90 para cenário 3 e configurações 3-3-1 e 3-6-1; ii) verificação: R=0,99 e 0,68 e NS=0,99 e -0,93 para cenário 1 e configurações 3-3-1 e 3-6-1; R=NS=0,99 para cenário 2 (3-3-1); R=0,48 e 0,95 e NS=0,18 e 0,90 para cenário 3 e configurações 3-3-1 e 3-6-1; b) sedimentos: i) treinamento: R=NS=0,99 e 1,00 para cenário 1 e configurações 6-6-1 e 6-12-1; R=0,98 e NS=0,99 para cenário 2 (3-3-1); R=NS=0,9 para cenário 3 (4-5-1); ii) verificação: R=0,99 e -0,52 e NS=0,98 e -0,92 para cenário 1 e configurações 6-6-1 e 6-12-1; R=0,89 e NS=0,79 para cenário 2; R=0,81 e NS=0,66 para cenário 3 Análise por evento: a) W2: NS variou entre 0,836 e 0,999 no treinamento e entre 0,579 e 0,966 na verificação; b) W7: NS variou entre 0,9504 e 0,9998 no treinamento e entre 0,9718 e 0,9969 na verificação	melhor desempenho: a) vazão: cenário 1 > cenário 2 > cenário 3 para W2 e W7; b) sedimentos: i) W2: cenário 1 (7-7-1) > cenário 4 (3-9-1) > cenário 3 (3-4-1) > cenário 2 (6-6-1) para W2 e cenário 1 (6-6-1) > cenário 2 > cenário 3 para W7
Wang, Traore e Kerh (2008)	reservatório Jiasian, rio Chishan, Taiwan	-	avaliar a potencialidade das RNAs prever a CSS horária	RNA feedforward (3 camadas), análise de regressão e generalized regression neural network (GRNN)	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão horária (Q) e turbidez horária (T) cenários: 1) Q_t e T_{t-1} ; 2) T_t ; 3) Q_t	CSS _t	1309 dados: 18/07/2002-10/10/2002	horária	RNA feedforward: a) treinamento: R²=0,977 (2-4-1); 0,929 (1-2-1); 0,883 (1-2-1) para cenários 1, 2 e 3; b) verificação: R²=0,930; 0,915 e 0,524 para cenários 1, 2 e 3 GRNN: a) treinamento: R²=0,958 (2-0,01-1); 0,934 (1-0,01-1) e 0,896 (1-0,01-1) para cenários 1, 2 e 3; b) verificação: R²=0,927; 0,919 e 0,558 para cenários 1, 2 e 3	melhores modelos para cenário 1
Zhu, Lu e Zhou (2008)	bacia de Longchuanjiang, China	5560 km²	avaliar, através de RNAs, a sensibilidade do fluxo de sedimentos em suspensão em relação às mudanças climáticas	perceptron de múltiplas camadas (3 camadas)	retropropagativo (Gradiente de Descida)	dados mensais médios: precipitação (P), temperatura (T), intensidade dos eventos (P ₂₅ -P acumulada ≥ 25 mm por dia no mês e; P ₅₀ -P acumulada ≥ 50 mm por dia no mês) e vazão (Q) cenários: 1) P_t e T_{t-1} ; 2) T_t, P_t, T_{t-1} e P_{t-1} ; 3) $P_t, T_t, P_{t-1}, T_{t-1}, P_{t-2}$ e T_{t-2} ; 4) $T_t, P_t, P_{25t}, P_{50t}$; 5) $T_t, P_t, P_{25t}, P_{50t}, T_{t-1}$ e P_{t-1} ; 6) $T_t, P_t, P_{25t}, P_{50t}, T_{t-1}, P_{t-1}, T_{t-2}$ e P_{t-2} ; 7) T_t, P_t e $Q_{obs(t)}$; 8) P_t, T_t e $Q_{est(t)}$, sendo $Q_{est} = f(T_t, P_t, P_{25t}, P_{50t}, T_{t-1})$ e $P_{t-1}, T_{t-2}, P_{t-2}, T_{t-3}$ e P_{t-3} em um modelo RNA proposto por Zhu et al. (2006)	descarga de sedimentos suspensos (Q _s)	1960, 1963, 1965-1966 e 1970-1990. Foram utilizados 96 dados para treinamento, 40 para validação cruzada e 64 para verificação	mensal	a) treinamento: R²=0,721; 0,838; 0,839; 0,728; 0,841; 0,840; 0,876; 0,960 e 0,854 para cenários 1 a 8; b) validação cruzada: R²=0,649; 0,781; 0,782; 0,678; 0,794; 0,801; 0,900; 0,913 e 0,865 para cenários 1 a 8; c) verificação: R²=0,750; 0,797; 0,800; 0,730; 0,808; 0,818; 0,816; 0,814 e 0,812 para cenários 1 a 8	RNA cenário 5 foi utilizada para análises das variações climáticas (alterações de temperatura e precipitação)

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Anctil, Filion e Tournebize (2009)	bacia de Melarchez (Paris, França)	7,1 km²	simulação do fluxo diário de sedimentos na bacia	perceptron de múltiplas camadas (3 camadas)	retropropagativo Levenberg-Marquardt com regularização Bayesiana	precipitação diária (P), vazão (Q), fluxo de nitrato-nitrogênio e fluxo de sedimentos 12 entradas testadas individualmente: 1) Q _t ; 2) Q _{t-1} ; 3) ΔQ; 4) P _t ; 5) P _{t-1} ; 6) fluxo histórico médio (F*); 7) incremento do fluxo histórico médio (ΔF*=F _t -F _{t-1}); 8) índice de umidade do solo a 10 cm (SMI ₁₀); 9) SMI ₂₀ ; 10) SMI ₄₀ ; 11) SMI ₈₀ ; 12) SMI ₁₂₀ . O melhor modelo individual é testado com cada um dos restantes (individual) e o par de melhor modelo vai sendo testado com as demais variáveis. O processo é repetido até encontrar melhor modelo.	fluxo de sedimentos	1975-1993: dados foram divididos utilizando Self-organizing feature maps: 2/3 utilizados para treinamento e 1/3 para verificação	diário	Processo de verificação: variáveis individuais: NS variou entre 0,009 (ΔF*) e 0,173 (Q _t) 2 variáveis: Q _t (melhor de 1 variável) e F*. NS variou entre 0,170 (Q _t e ΔQ) e 0,716 (Q _t e F*) 3 variáveis: Q _t e F* associado a ΔQ. NS variou entre 0,573 (Q _t , F* e SMI ₁₀) e 0,769 (Q _t , F* e ΔQ)	-
Cobaner, Unal Kisi (2009)	bacia do rio Mad (Arcata, Califórnia, EUA)	1256,14 km²	estimar a CSS por modelo adaptativo neuro-fuzzy e 3 tipos de RNAs	RNA= perceptron de múltiplas camadas (3 camadas); base radial e RNA de regressão generalizada (GRNN), neuro-fuzzy e curva-chave tradicional	Levenberg-Marquardt (RNA perceptron de múltiplas camadas)	vazão (Q), precipitação (P) e CSS antecedente para s RNAs: Q _t , Q _{t-1} , CSS _{t-1} , CSS _{t-2} e P _t (= melhor combinação para o modelo adaptativo neuro-fuzzy)	CSS _t	731 dados para treinamento (1971-1972) e 365 para verificação (1973)	diário	treinamento: R²=0,952 (neuro-fuzzy); 0,998 (GRNN); 0,938 (RNA base radial) e 0,915 (perceptron múltiplas camadas) verificação: R²=0,880 (neuro-fuzzy); 0,792 (GRNN); 0,852 (RNA base radial) e 0,802 (perceptron múltiplas camadas)	o modelo adaptativo neuro-fuzzy apresenta melhor desempenho em relação às RNAs
Jothiprakash e Garg (2009)	reservatório de Gobindsagar, Bhakra Dam, rio Satluj, distrito de Bilaspur, Himachal Pradesh, Índia	168,35 km²	estimar o volume de sedimentos retidos no reservatório	perceptron múltiplas camadas (3 camadas)	vários algoritmos retropropagativo: com propagação resiliente, gradiente de descida com uso do momento, gradiente de descida com aprendizado adaptativo, a combinação dos 2 últimos, método de secante em um passo e; Levenberg-Marquardt	precipitação anual (P _a), fluxo de entrada anual (I _a) e capacidade disponível no ano (C _a)	volume de sedimentos retido (S _v)	30 anos: 23 para treinamento e 9 para verificação	anual	R=0,970 para treinamento e 0,965 para verificação	configuração da RNA: 3-5-1 variáveis mais importantes: P _a , C _a e I _a
Kisi et al. (2009)	2 estações (Kuyulus e Sahur Koprusu) na bacia do rio Kizilirmak, Turquia	Kuyulus=3935 km² Sahur Koprusu= 30589 km²	estimativa dos sedimentos suspensos	RNA (feedforward 3 camadas), neuro-fuzzy e modelos baseados em análises de regressão	Levenberg-Marquardt		sedimentos suspensos (S _s)	Kuyulus: 180 dados para treinamento (03/1981-12/1995) e 45 para verificação (01/1996-09/1999) Sahur Koprusu: 226 para treinamento (12/1972-09/1992) e 57 para verificação (10/1992-04/1997)	mensal	Kuyulus: R=0,766 (função de ativação sigmoide logarítma na camada de saída e 6 neurônios camada intermediária) e R=0,762 (função de ativação linear na camada de saída e 6 neurônios camada intermediária); para verificação Sahur Koprusu: R=0,740 (unção de ativação sigmoide logarítma na camada de saída e 2 neurônios camada intermediária) e R=0,388 (função de ativação linear na camada de saída e 6 neurônios camada intermediária); para verificação	-
Nourani (2009)	estação de Akhule, rio Talkherood, Província de Azarbayjan, Irã	~13853 km²	estimativa da carga de sedimentos	feedforward (3 camadas)	Levenberg-Marquardt	vazão (Q). Cenários: 1) Q _t ; 2) Q _t e Q _{t-1} ; 3) Q _t , Q _{t-1} e Q _{t-2} . O número de neurônios na camada intermediária, investigado em cada cenário, variou de 2 a 10	descarga de sedimentos (Q _{st})	vazão: 2002-2005, sendo 75% (3 anos) para treinamento e 25% (1 ano) para verificação sedimentos: 380 dados (2002-2005)	diário	cenário 1: a) treinamento: NS=0,973 (para 2, 3, 4, 5, 7, 9 e 10 neurônios) e NS=0,961 e 0,952 para 6 e 8 neurônios e; b) verificação: NS=0,878 (para 2, 3, 4, 7 e 9 neurônios) e NS=0,869; 0,834; 0,833 e 0,877 para 5, 6, 8 e 10 neurônios cenário 2: a) treinamento: NS=0,973 para 2, 3, 4, 5, 7, 9 e 10 neurônios e NS=0,972 e 0,975 para 6 e 8 neurônios; b) verificação: NS=0,900; 0,881; 0,862; 0,863; 0,874; 0,858; 0,916; 0,878 e 0,869 para 2 a 10 neurônios testados cenário 3: a) treinamento: NS=0,977 para 2, 8, 9 e 10 neurônios e NS=0,980; 0,978; 0,980; 0,979 e 0,980 para 3, 4, 5, 6 e 7 neurônios; b) verificação: NS=0,886; 0,925; 0,922; 0,912; 0,935; 0,913; 0,865; 0,875 e 0,898 para 2 a 10 neurônios testados	melhor resultado verificação: 6 neurônios na camada intermediária e entrada cenário 3
Rajaei et al. (2009)	2 estações (rio Little Black, e rio Salt), estado de Missouai, EUA	Little Black: 194 milhas² Salt: 2480 milhas²	estimar a CSS diária	RNA feedforward (3 camadas), sistema neuro-fuzzy e curva chave tradicional	Levenberg-Marquardt	cenários RNA: 1) CSS _{t-1} e Q _{t-1} ; 2) CSS _{t-1} , CSS _{t-2} , Q _{t-1} e Q _{t-2} ; 3) CSS _{t-1} , CSS _{t-2} , CSS _{t-3} , Q _{t-1} , Q _{t-2} e Q _{t-3} ; 4) CSS _{t-1} , Q _t e Q _{t-1} ; 5) CSS _{t-1} , CSS _{t-2} , Q _t , Q _{t-1} , Q _{t-2} ; 6) CSS _{t-1} , CSS _{t-2} , CSS _{t-3} , Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}	CSS _t	Little Black: 3 anos (01/10/1980-30/09/1983) para treinamento e 1 ano (01/10/1983-30/09/1984) para verificação Salt: 3 anos (01/10/1984-30/09/1987) para treinamento e 1 ano (01/10/1987-30/09/1988) para verificação	diário	Little Black: R²=0,073; 0,0002; 0,0005; 0,457; 0,207 e 0,328 para cenários 1 a 6 Salt: R²=0,327; 0,335; 0,307; 0,298; 0,345 e 0,154 para cenários 1 a 6	-
Ulke, Tayfur e Ozkul (2009)	rio Gediz, Turquia	17500 km²	avaliar a capacidade dos modelos em prever os sedimentos suspensos Semi-mensais e preencher lacunas diárias	RNA feedforward (3 camadas), sistema de interferência neuro-fuzzy, regressão multilinear, regressão múltipla não linear, curva chave tradicional	Levenberg-Marquardt (LM) e Gradiente Conjugado (GC)	vazão diária média (Q) e precipitação total diária (P) cenários: 1) Q _t ; 2) Q _t e Q _{t-1} ; 3) P _t e Q _t ; 4) P _t , Q _t e Q _{t-1} ; 5) P _t , P _{t-1} , Q _t e Q _{t-1}	carga de sedimento suspenso (S _s)	351 dados (01/01/1975-01/08/2005). Foram criados 2 grupos de dados: G1: a) treinamento: 05/01/1975-13/02/1979 e 02/04/1987-01/08/2005; b) verificação: 13/03/1979-03/03/1987 G2: a) treinamento: 17/05/1983-01/08/2005; b) verificação: 05/01/1975-20/04/1983	semi-mensal	Dados G1: a) algoritmo LM: R²=0,85; 0,97; 0,99; 0,92 e 0,99 para cenários 1 a 5 no treinamento e; R²=0,80; 0,76; 0,87; 0,75 e 0,93 para cenários 1 a 5 na verificação; b) algoritmo GC: R²=0,81; 0,90; 0,94; 0,93 e 0,97 para cenários 1 a 5 no treinamento e; R²=0,71; 0,71; 0,71; 0,71 e 0,92 para os cenários 1 a 5 na verificação Dados G2: a) algoritmo LM: R²=0,80; 0,97; 0,91; 0,93 0,99 para cenários 1 a 5 no treinamento e; R²=0,67; 0,75; 0,87; 0,71 e 0,65 para cenários 1 a 5 na verificação; b) algoritmo GC: R²=0,80; 0,89; 0,90; 0,85 e 0,91 para cenários 1 a 5 no treinamento e; R²=0,66; 0,78; 0,89; 0,84 e 0,70 para cenários 1 a 5 na verificação	RNA com algoritmo GC teve o melhor desempenho entre os modelos analisados
Wang e Traore (2009)	2 estações (Liukwei e Lao-Nung) na bacia do rio Kaoping, Taiwan	3257 km²	estimativa da carga de sedimentos suspensos	perceptron de múltiplas camadas (3 camadas)	retropropagativo (Gradiente de Descida)	precipitação (P), nível de água (N) e vazão (Q) cenários: 1) Q _t ; 2) P _t ; 3) N _t ; 4) Q _t e P _t ; 5) Q _t e N _t ; 6) P _t e N _t ; 7) Q _t , P _t e N _t	carga de sedimento suspenso (S _s)	647 valores (1984-2005): 70% para treinamento, 20% para validação cruzada e 10% para verificação	diário	Liukwei: R²=0,944; 0,525; 0,021; 0,763; 0,169; 0,05 e 0,087 para cenários 1 a 7 na verificação Lao-Nung: R²=0,801; 0,050; 0,250; 0,237; 0,475; 0,06 e 0,407 para cenários a 7 na verificação	melhor modelo para cenário 1 nas duas estações
Wang, Kerh e Traore (2009)	reservatório Jiasian, rio Chishan, Taiwan	-	avaliar a potencialidade das RNAs prever a CSS horária	RNA feedforward (3 camadas), análise de regressão e; generalized regression neural network (GRNN)	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão horária (Q) e turbidez horária (T) cenários: 1) Q _t e T _t ; 2) T _t ; 3) Q _t	CSS _t	1309 dados de eventos de julho a outubro de 2002 (18/07/2002-10/10/2002), sendo 50% usado para treinamento e 50% para verificação	horário	RNA feedforward: a) treinamento: R²=0,951 (2-4-1); 0,924 (1-2-1); 0,879 (1-2-1) para cenários 1, 2 e 3; b) verificação: R²=0,943; 0,938 e 0,846 para cenários 1, 2 e 3 GRNN: a) treinamento: R²=0,979 (2-0,01-1); 0,930 (1-0,01-1) e 0,894 (1-0,01-1) para cenários 1, 2 e 3; b) verificação: R²=0,925; 0,931 e 0,836 para cenários 1, 2 e 3	melhores modelos para cenário 1

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R ² /R	Outras observações/conclusões
Nourani e Kalantari (2010)	8 estações na bacia do rio Eel, Califórnia, EUA	8051 km ²	desenvolver modelos para estimar a carga de sedimentos suspensos nas estações e em qualquer ponto da bacia	feedforward (3 camadas)	Levenberg-Marquardt	testados P _t ; Q _t ; Q _{t-1} ; Q _{t-2} ; Q _{t-3} cenários: 1) 1 RNA (RNA 1) para cada estação (estação 1 a 6); 2) 1 única RNA (RNA 1) para as 6 estações (entrada: dados de todas as estações; saída: S _t em cada estação); 3) RNA 2: dados de entrada separados por grupo através do método de agrupamento K-means (Análise Cluster), sendo as estações classificadas em 2 grupos (RNA distintas para cada grupo e desempenho verificado para cada estação)	carga de sedimento suspenso (S _t)	12/1966-09/1969 para treinamento e 10/1969-09/1970 para verificação	diário	cenário 1: a) estação 1: NS=0,925 e 0,862 para treinamento e verificação (5-8-1; entrada: P _t , Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}); b) estação 2: NS=0,934 e 0,761 para treinamento e verificação (5-8-1; entrada: P _t , Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3}); c) estação 3: NS=0,921 e 0,841 para treinamento e verificação (4-7-1; entrada: P _t , Q _t , Q _{t-1} , Q _{t-2}); d) estação 4: NS=0,913 e 0,865 para treinamento e verificação (4-5-1; entrada: P _t , Q _t , Q _{t-1} , Q _{t-2}); e) estação 5: NS=0,930 e 0,820 para treinamento e verificação (3-6-1; entrada: P _t , Q _t , Q _{t-1}); e) estação 6: NS=0,895 e 0,790 para treinamento e verificação (3-6-1; entrada: P _t , Q _t , Q _{t-1}) cenário 2: a) treinamento: NS=0,942; 0,950; 0,940; 0,933; 0,942 e 0,940 para estações 1 a 6 (24-20-6; entrada: P _t , Q _t , Q _{t-1} , Q _{t-2} em cada estação); b) verificação: NS=0,860; 0,780; 0,840; 0,844; 0,820; 0,818 para estações 1 a 6 cenário 3: sub-bacias 1 e 2 foram colocadas em um grupo e as demais em outro. a) Estações 1 e 2 (8-12-2): NS=0,97 e 0,981 no treinamento e 0,92 e 0,802 na verificação, para estações 1 e 2; b) estações 3 a 6 (16-14-4): NS=0,907; 0,951; 0,947 e 0,923 para o treinamento e NS=0,914; 0,945; 0,885 e 0,857 na verificação, para estações 3 a 6	
Talebizadeh et al. (2010)	bacia de Kasilian, Irã	69 km ²	avaliar o desempenho e incertezas de 2 modelos (SWAT e RNA) para estimativa da carga de sedimentos	perceptron de múltiplas camadas (3 camadas)	retropropagativo (Gradiente de Descida)	vazão média diária (Q), precipitação diária (P) cenários: 1) Q _t ; 2) Q _t e P _t ; 3) Q _t e Q _{t-1}	carga de sedimento suspenso (S _t)	1971-1973 para treinamento e 1974-1976 para verificação	diário	R ² =0,75 (1-5-1) para cenário 1; 0,76 (2-5-1) para cenário 2 e; 0,73 (2-7-1) para cenário 3	SWAT prediz melhor as cargas de sedimentos mais elevadas enquanto que a RNA tem melhor desempenho para as cargas pequenas e médias
Melesse et al. (2011)	três rios (Mississippi, Missouri e Rio Grande) nos EUA. Estações usadas em: 1) Mississippi: Tarbert Landing (Louisiana) com A=2880768 km ² ; 2) Missouri: Bismarck (North Dakota) com A=477184 km ² ; 3) Rio Grande: Albuquerque (New Mexico) com A=44646 km ²	Mississippi: 4,76 milhões de km ² ; Missouri: 1,3 milhões de km ² ; Rio Grande: 472000 km ²	estimar a carga de sedimentos suspensos diária e semanal	perceptron múltiplas camadas (3 camadas). Resultados comparados a regressão linear múltipla, regressão não-linear múltipla e modelo auto-regressivo integrado de média móvel	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão (Q) e carga de sedimentos suspensos (S) cenários: 1) P _t , Q _t , Q _{t-1} e S _{t-1} ; 2) Q _t , Q _{t-1} e S _{t-1} ; 3) Q _t e S _{t-1}	carga de sedimentos suspensos (S _t) diária e semanal	1971 a 1975 para o Rio Mississippi e 1977 a 1981 para os rios Missouri e Rio Grande. Foram testadas diferentes divisões de dados para treinamento (Tr) e verificação (Vr): i) (3*2) - 3 anos para Tr e 2 para Vr; ii) (2*3) - 2 anos para Tr e 3 para Vr; iii) (4*1) - 4 anos para Tr e 1 para Vr	diário e semanal	diário (divisão 3*2): R ² =0,96; 0,95 e 0,93 e NS=0,80; 0,75 e 0,71 para cenários (entradas) 1, 2 e 3 em Mississippi; R ² =0,97; 0,97 e 0,92 e NS=0,80; 0,94 e 0,91 para cenários 1, 2 e 3 em Missouri; R ² =0,65; 0,65 e 0,56 e NS=0,46; 0,46 e 0,38 para cenários 1, 2 e 3 em Rio Grande semanal (divisão 3*2): R ² =0,87; 0,84 e 0,80 e NS=0,60; 0,60 e 0,53 para cenários (entradas) 1, 2 e 3 em Mississippi; R ² =0,84; 0,70 e 0,64 e NS=0,55; 0,32 e 0,44 para cenários 1, 2 e 3 em Missouri; R ² =0,40; 0,40 e 0,30 e NS=0,25; 0,26 e 0,20 para cenários 1, 2 e 3 em Rio Grande divisão dados (diário): a) Mississippi: R ² =0,98; 0,96 e 0,72 e NS=0,84; 0,80 e 0,70 para divisão 4*1, 3*2 e 2*3; b) Missouri: R ² =0,5; 0,97 e 0,64 e NS=0,80; 0,80 e 0,30 para divisão 4*1, 3*2 e 2*3; c) Rio Grande: R ² =0,57; 0,65 e 0,57 e NS=0,43; 0,46 e 0,30 para divisão 4*1, 3*2 e 2*3	previsão em Mississippi e Missouri é melhor do que em Rio Grande. RNA respondeu melhor a estimativa da S _t , tanto para valores semanais quanto diário
Yenigün et al. (2010)	5 estações (2102, 2115, 2119, 2133 e 2145) na bacia Euphrates, Turquia	127304 km ²	desenvolver um modelo RNA para previsão da produção de sedimentos para ser utilizado no lugar das fórmulas tradicionais (Schoklitsch, Shields, Du Boys, Garde, Albertson, Meyer-Peter-Müller)	perceptron de múltiplas camadas (3 camadas), curva chave observacional e equações tradicionais	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão (Q)	produção de sedimentos	1937-1980	diário	R ² = 0,856; 0,822; 0,799 e 0,734 para as estações 2102, 2115, 2119, 2133 e 2145. Configuração: 1-9-1 para estações 2102, 2115, 2119 e 1-11-1 para as demais	RNA apresentou melhores resultados para as 5 estações analisadas
Mustafa, Isa e Rezaur (2011)	estação Silbin, rio Pari, Perak, Malásia	245 km ²	comparar o desempenho de duas RNAs para a previsão da descarga de sedimentos suspensos	RNA de base radial e feedforward (3 camadas)	Levenberg-Marquardt	vazão (Q)	descarga de sedimentos suspenso diária (S _t)	5 anos (1993-1998): 06/01/1993 a 03/03/1997 para treinamento e 04/03/1997 a 24/10/1998 para verificação	diário	NS= 0,999 (treinamento) e 0,997 (verificação) para a RNA de base radial e NS=0,996 (treinamento) e 0,990 (verificação) para a RNA feedforward	RNA de base radial produz resultados um pouco melhores que a RNA feedforward, mas requer maior número de neurônios na camada intermediária (100)
Mount e Abrahart (2011)	2 estações (Rio Valenciano e Quebrada Blanca) em Porto Rico	Valenciano: 43,57 km ² Quebrada Blanca: 863 km ²	analisar o emprego de RNAs para previsão da CSS ou da carga de sedimentos suspensos, complexidades internas e a necessidade de transformação dos dados de entrada	RNA feedforward (3 camadas)	regularização Bayesiana associada ao algoritmo Levenberg-Marquardt	vazão (Q). Os dados de entrada foram separados por faixa e foram testados com entrada não transformada e transformada (logaritmo). O número de neurônios testados na camada intermediária variou de 1 a 5 (M1, M2, M3, M4 e M5)	2 tipos de saídas testadas: carga de sedimentos suspensos (S _t) e CSS _t	5843 para Rio Valenciano e 5477 para Quebrada Blanca, sendo 4043 para treinamento em Rio Valenciano e 3677 em Quebrada Blanca. Os demais (1800) foram utilizados para verificação das RNAs	diário	Rio Valenciano: a) CSS: R ² =0,63; 0,76; 0,78; 0,81 e 0,81 no treinamento e R ² =0,38; 0,58; 0,59; 0,37 e 0,36 na verificação; considerando M1, M2, M3, M4 e M5; b) S _t : R ² =0,92; 0,96; 0,97; 0,98 e 0,98 no treinamento e R ² =0,21; 0,23; 0,15; 0,13 e 0,11 na verificação; considerando M1, M2, M3, M4 e M5 Quebrada Blanca: a) CSS: R ² =0,77; 0,82; 0,83, 0,85 e 0,89 no treinamento e R ² =0,79; 0,82; 0,83; 0,72 e 0,71 na verificação; considerando M1, M2, M3, M4 e M5; b) S _t : R ² =0,60; 0,61; 0,61; 0,61 e 0,61 no treinamento e R ² =0,72; 0,79; 0,80; 0,85 e 0,85 na verificação dados transformados (log) - Rio Valenciano: a) CSS: R ² =0,48; 0,59; 0,52; 0,53 e 0,49 no treinamento e R ² =0,71; 0,68; 0,70; 0,70; e 0,71 na verificação; considerando M1, M2, M3, M4 e M5; b) S _t : R ² =0,51; 0,52; 0,52; 0,53 e 0,53 no treinamento e R ² =0,78; 0,78; 0,78; 0,78 e 0,77 na verificação; considerando M1, M2, M3, M4 e M5 dados transformados (log) - Quebrada Blanca: a) CSS: R ² =0,73; 0,74; 0,74; 0,74 e 0,74 no treinamento e R ² =0,84; 0,83; 0,84; 0,84 e 0,84 na verificação; considerando M1, M2, M3, M4 e M5; b) S _t : R ² =0,58; 0,60; 0,61; 0,61 e 0,61 no treinamento e R ² =0,82; 0,75; 0,73; 0,73 e 0,73 na verificação; considerando M1, M2, M3, M4 e M5	
Rajaei et al. (2011)	rio Iowa, Wapello, EUA	12499 milhas ²	estimar a carga diária de sedimentos suspensos	RNA (feedforward - 3 camadas); RNA Wavelet; regressão linear múltipla e curva chave tradicional	Levenberg-Marquardt	vazão (Q) e carga de sedimentos suspensos (S). Para RNA Wavelet, os dados foram decompostos por 7 tipos de transformada em vários níveis (até 5 níveis) cenários RNA (feedforward): 1) S _t ; 2) S _t e S _{t-1} ; 3) S _t , S _{t-1} e S _{t-2} ; 4) S _t e Q _t ; 5) S _t , S _{t-1} e Q _t ; 6) S _t , S _{t-1} , Q _t e Q _{t-1}	carga de sedimentos suspensos (S _t)	7 anos (01/10/1978-30/09/1985) para treinamento e 2 anos (01/10/1985-30/09/1987) para verificação	diário	resultados para verificação RNA feedforward: NS=0,612; 0,670; 0,644; 0,611; 0,635 e 0,642 para cenários 1 a 6 RNA Wavelet: NS variou entre -0,07 e 0,812 (4-1-1 e 1 nível de decomposição)	

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Rajaei (2011)	rio Yadkin, Virginia, EUA	2280 milhas²	estimar a carga diária de sedimentos suspensos	RNA (feedforward - 3 camadas), RNA Wavelet, regressão linear múltipla e curva chave tradicional	RNA: retropropagativo (Levenberg-Marquardt)	vazão (Q) e carga de sedimentos suspensos (S). Para RNA Wavelet dados foram decompostos em 5 níveis para gerar as entradas. Foram testadas 7 tipo de transformadas Wavelet cenários RNA: 1) S _t ; 2) S _t e S _{t-1} ; 3) S _t , S _{t-1} e S _{t-2} ; 4) S _t e Q _t ; 5) S _t , S _{t-1} e Q _t ; 6) S _t , S _{t-1} , Q _t e Q _{t-1}	carga de sedimentos suspensos (S _t)	25 anos (01/10/1957-30/09/1982) para treinamento e 5 anos (01/10/1982-30/09/1987) para verificação	diário	resultados para verificação RNA feedforward: NS=0,261; 0,347; 0,341; 0,264; 0,414 e 0,349 para cenários 1 a 6 RNA Wavelet: NS variou entre 0,549 e 0,830 (2 níveis de decomposição)	
Singh e Panda (2011)	bacia de Kappari e suas sub-bacias KGSW1, KGSW2 e KGSW3; Jamboni block, Distrito de Jamboni block	973 hectares	estimativa da produção de sedimentos diária	feedforward (3 camadas)	retropropagativo (Levenberg-Marquardt)	precipitação (P), temperatura máxima (T _{max}), temperatura mínima (T _{min}) cenários: 1) P _t ; 2) P _t e P _{t-1} ; 3) P _t , P _{t-1} , T _{max} e T _{min}	produção de sedimentos	2003-2005: 2004 e 2005 para treinamento e validação cruzada e 2003 para verificação	diário	Cenário 3 teve melhores resultados para todos os locais analisados a) treinamento: NS= 0,943 e R²= 0,951 para Kappari (RNA 4-4-1), NS=0,921 e R²=0,932 para KGSW1 (RNA 4-4-1), NS=0,946 e R²=0,955 para KGSW2 (RNA 4-3-1), NS=0,956 e R²=0,958 para KGSW3 (RNA 4-3-1); b) verificação: NS= 0,792 e R²=0,869 para Kappari, NS=0,756 e R²=0,821 para KGSW1, NS=0,829 e R²=0,887 para KGSW2, NS=0,806 e R²=0,821 para KGSW3	
Bayram, Kankal e Önsoy (2012)	sub-bacia de Harsit (6 estações monitoradas), Turquia	3280 km²	estimar a CSS a partir de dados de turbidez	RNA (feedforward 3 camadas), análise de regressão	retropropagativo (Gradiente de Descida)	turbidez	CSS _t	03/2009 a 02/2010: 108, 24 e 12 dados para treinamento, validação (teste) e verificação	quinzenal	-	RNA tem bons resultados para prever CSS: EaM = 12,60 (validação) e 11,40 (verificação) e RMSE= 21,96 (validação) e 17,87 (verificação)
Feyzolahpour, Rajabi e Roostaie (2012)	rio Givichay, Irã	área drenada de 827 km²	estimar a concentração de sedimentos pelo modelo EDN e comparar com modelos RNA	evolução diferencial neural; curvas-chave tradicionais; perceptron de múltiplas camadas e RNA de base radial	Levenberg-Marquardt (perceptron de múltiplas camadas)	entrada RNAs: Q _t (melhor resultado modelo EDN) entradas testadas para EDN: 1) Q _t ; 2) Q _t e Q _{t-1} ; 3) Q _t e S _{t-1} ; 4) Q _t , Q _{t-1} e S _{t-1}	concentração de sedimento (S _t)	treinamento: 01/09-06/09 verificação: 180 dias (01/10-06/10)	diário	R²= 0,9621 (EDN); 0,9114 (RNA de base radial) e 0,90 para RNA perceptron de múltiplas camadas	os modelos RNA e curva-chave foram desenvolvidos para comparação com o modelo de evolução diferencial neural (EDN). As entradas do melhor modelo EDN foram usadas para os demais modelos RNAs
Kisi (2012)	2 estações (montante e jusante) no rio Eel, Califórnia, EUA	montante: 1368 km² jusante: 8063 km²	estimativa da CSS diária por Máquinas de Vetores de Transporte, comparadas a RNA e curva-chave tradicional	Máquinas de Vetores de Suporte, RNA feedforward (3 camadas) e curva-chave tradicional	retropropagativo: Levenberg-Marquardt (LM) e Gradiente Conjugado (GC)	vazão (Q) Cenários testados: 1) Q _t ; 2) Q _t e Q _{t-1} ; 3) Q _t , Q _{t-1} e Q _{t-2} ; 4) Q _t , Q _{t-1} , Q _{t-2} e Q _{t-3} . Entradas testadas usando dados de cada estação (montante e jusante) para prever a saída nelas mesmas previsão à jusante: i) usando dados à montante - cenários: 1) Q _{tm} ; 2) Q _{tm} e Q _{tm-1} ; 3) Q _{tm} , Q _{tm-1} e Q _{tm-2} ; 4) Q _{tm} , Q _{tm-1} , Q _{tm-2} e Q _{tm-3} ; ii) usando dados montante e jusante - cenários: 1) Q _{tm} , Q _{tm-1} , Q _{tm-2} , Q _{tm-3} e Q _{tm-4}	CSS _t	01/10/1966-30/09/1973 para treinamento; 01/10/1973-30/09/1975 para validação e; 01/10/1975-30/09/1977 para verificação	diário	montante: 1) treinamento: R²=0,918; 0,945; 0,938 e 0,959 para LM - nos cenários 1, 2, 3 e 4 e; R²=0,916; 0,944; 0,950 e 0,956 para GC nos cenários 1, 2, 3 e 4 e; 2) validação: R²=0,815; 0,812; 0,826 e 0,752 para LM nos cenários 1, 2, 3 e 4 e; R²=0,814; 0,820; 0,820 e 0,815 para GC nos cenários 1, 2, 3 e 4; 3) verificação: 0,975 para LM e GC, cenário 2 jusante: 1) treinamento: R²=0,822; 0,929; 0,935 e 0,964 para LM - nos cenários 1, 2, 3 e 4 e; R²=0,821; 0,928; 0,954 e 0,937 para GC nos cenários 1, 2, 3 e 4 e; 2) validação: R²=0,811; 0,936; 0,897 e 0,864 para LM nos cenários 1, 2, 3 e 4 e; R²=0,802; 0,921; 0,855 e 0,859 para GC nos cenários 1, 2, 3 e 4; 3) verificação: 0,992 para LM e GC, cenário 2 jusante usando dados montante: 1) treinamento: R²=0,879; 0,876; 0,888 e 0,899 para LM - nos cenários 1, 2, 3 e 4 e; R²=0,870; 0,871; 0,892 e 0,900 para GC nos cenários 1, 2, 3 e 4 e; 2) validação: R²=0,915; 0,913; 0,931 e 0,906 para LM nos cenários 1, 2, 3 e 4 e; R²=0,915; 0,925; 0,933 e 0,921 para GC nos cenários 1, 2, 3 e 4; 3) verificação: 0,929 para LM e 0,913 GC, ambos para cenário 3 jusante usando dados montante e jusante (cenário 1): 1) treinamento: R²=0,949 e 0,953 para LM e GC; 2) validação: R²=0,914 e 0,943 para LM e GC; 3) verificação: R²= 0,990 e 0,993 para LM e GC	configuração RNA montante: 1) LM: 1-4-1; 2-3-1; 3-4-1 e 4-3-1 para cenários 1, 2, 3 e 4 e; 2) GC: 1-3-1; 2-9-1; 3-4-1 e 4-4-1 para cenários 1, 2, 3 e 4. Melhor RNA-LM (2-3-1) e RNA-GC (2-9-1) jusante: 1) LM: 1-1-1; 2-5-1; 3-5-1 e 4-8-1 para cenários 1, 2, 3 e 4 e; 2) GC: 1-1-1; 2-5-1; 3-9-1 e 4-7-1 para cenários 1, 2, 3 e 4. Melhor RNA (2-5-1) para LM e GC jusante usando dados montante: 1) LM: 1-10-1; 2-8-1; 3-4-1 e 4-5-1 para cenários 1, 2, 3 e 4 e. 2) GC: 1-5-1; 2-7-1; 3-4-1 e 4-7-1 para cenários 1, 2, 3 e 4. Melhor RNA-LM e RNA-GC (3-4-1) jusante usando dados montante e jusante: 5-3-1 para LM e 5-6-1 para GC (cenário 1)
Kisi e Shiri (2012)	rio Eel (próximo ao rio Dos), Califórnia, EUA	528 km²	estimar a carga diária de sedimentos suspensos	RNA, sistema de inferência neuro-fuzzy adaptativo (ANFIS), e Programação de Expressão Genética (GEP)	para a RNA: Levenberg-Marquardt (RNA1), Gradiente Conjugado (RNA2) e Gradiente de Descida (RNA3)	precipitação diária (P) e vazão (Q) cenários RNA: 1) Q _t ; 2) Q _{t-1} , Q _t ; 3) Q _{t-2} , Q _{t-1} , Q _t ; 4) Q _{t-3} , Q _{t-2} , Q _{t-1} , Q _t ; 5) Q _{t-2} , Q _{t-1} , Q _t , P _t ; 6) Q _{t-2} , Q _{t-1} , Q _t , P _{t-1} , P _t ; 7) Q _{t-2} , Q _{t-1} , Q _t , P _{t-2} , P _{t-1} , P _t	carga de sedimento suspenso (S _t)	-	diário	Combinação 5): R=0,929 e NS=0,838 para RNA1 (4-6-1); R=0,949 e NS=0,804 para RNA2 (4-9-1); R=0,820 e NS=0,801 para RNA (4-5-1) na verificação	
Kisi et al. (2012)	2 estações (Pineville e Barbourville) no rio Cumberland, EUA	Pineville= 2095 km² Barbourville: 960 milhas²	estimar a carga diária de sedimentos suspensos a partir de dados de vazão	RNA (feedforward - 3 camadas), sistema de inferência neuro-fuzzy adaptativo (ANFIS), Programação de Expressão Genética (GEP) e Máquina de Vetores de Suporte (SVM)	-	vazão (Q) cenários testados GEP: 1) Q _t ; 2) S _{t-1} ; 3) Q _t , S _{t-1} ; 4) Q _{t-1} , S _{t-1} ; 5) S _{t-1} , S _{t-2} ; 6) Q _t , Q _{t-1} , S _{t-1} ; 7) Q _{t-1} , Q _{t-2} , S _{t-1} , S _{t-2} ; 8) Q _t , Q _{t-1} , S _{t-1} , S _{t-2} RNA: cenário 6 (melhor cenário para GEP)	carga diária de sedimento (S _t)	10 anos: 01/10/1979 a 30/09/1989 01/10/1989-30/09/1986 para treinamento e 01/09/1986-30/09/1989 para verificação	diário	RNA (3,1,1): R²=0,848 para estação Barbourville e R²=0,889 para estação Pineville	objetivo principal é a previsão com modelos GEP. Demais modelos foram usados para comparação
Kisi, Ozkan e Akay (2012)	2 estações (rio Valenciano e Quebrada Blanca), Porto Rico	Valenciano: 43,57 km² Quebrada Blanca: 863 km²	investigar a relação vazão sedimentos suspensos usando RNA associada a algoritmo de colônia artificial de abelhas (RNA-ABC)	RNA (feedforward 3 camadas), evolução diferencial neural, RNA, neuro-fuzzy e curva-chave tradicional	algoritmo de colônia artificial de abelhas	vazão (Q) e CSS RNA-ABC cenários: i) Q _t ; ii) Q _t e Q _{t-1} ; iii) Q _t e CSS _{t-1} ; iv) Q _t , Q _{t-1} e CSS _{t-1} . Os mesmos cenários foram também testados com as entradas em formato logarítmico (RNA-ABC(log))	CSS _t	01/10/1993-30/09/1994 para treinamento e 01/10/1994-30/09/1995 para verificação	diário	verificação rio Valenciano: 1) RNA-ABC: R²= 0,883; 0,881; 0,883 e 0,886 para os cenários i), ii), iii) e iv); 2) RNA-ABC(log): R²=0,882; 0,881; 0,898 e 0,931 para os cenários i), ii), iii) e iv) Quebrada Blanca: 1) RNA-ABC: R²=0,948; 0,933; 0,933 e 0,931 para os cenários i), ii), iii) e iv); 2) RNA-ABC (log): R²=0,949; 0,957; 0,947 e 0,951 para os cenários i), ii), iii) e iv)	os demais modelos foram comparados com a RNA-ABC. configuração final por cenário: 1) RNA-ABC: i) 1-4-1; ii) 2-2-1; iii) 2-2-1 e iv) 3-3-1; 2) RNA-ABC (log): i) 1-3-1; ii) 2-2-1; iii) 2-2-1 e iv) 3-2-1

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Kumar et al. (2012)	bacia do rio Sutlej até Kasol, à montante do reservatório Bhakra, Índia	56980 km²	modelagem da CSS	RNA (feedforward - 3 camadas), RNA de base radial, lógica Fuzzy e algoritmos de árvore de decisão (M5 Model Tree e REPTree)	retropropagativo: Gradiente de Descida (GD) e Levenberg-Marquardt (LM)	fluxo de descarga (Q); precipitação e CSS cenário: $P_{R(t)}$; $P_{S(t)}$; $P_{K(t)}$; $Q_{K(t-1)}$; $Q_{K(t)}$; $CSS_{K(t-1)}$. Cenário proposto por Sudheer et al. (2002). Para verificar se o cenário de entradas proposto era o melhor foram testadas outras combinações: i) $P_{R(t-2)}$; $P_{R(t-1)}$; $P_{R(t)}$; $P_{S(t-2)}$; $P_{S(t-1)}$; $P_{S(t)}$; $P_{K(t-2)}$; $P_{K(t-1)}$; $P_{K(t)}$; $Q_{K(t-2)}$; $Q_{K(t-1)}$; $Q_{K(t)}$ e $CSS_{K(t-1)}$; ii) $P_{R(t-2)}$; $P_{R(t-1)}$; $P_{R(t)}$; $P_{S(t-2)}$; $P_{S(t-1)}$; $P_{S(t)}$; $P_{K(t-2)}$; $P_{K(t-1)}$; $P_{K(t)}$; $Q_{K(t-2)}$; $Q_{K(t-1)}$; $Q_{K(t)}$; $CSS_{K(t-1)}$; iii) $P_{R(t-1)}$; $P_{R(t)}$; $P_{S(t-1)}$; $P_{S(t)}$; $P_{K(t-1)}$; $P_{K(t)}$; $Q_{K(t-1)}$; $Q_{K(t)}$ e $CSS_{K(t-1)}$		3653 dias (1991-2000) para treinamento e 1461 (1987-1990) para verificação. Utilizados dados das estações de Rampur (R); Suni (S) e Kasol (K)	diário	treinamento: a) feedforward (RP): R=0,96; 0,99; 0,99; 0,99 e 0,99 e NS=0,92; 0,98; 0,98; 0,98; 0,98 e 0,98 para RNAs 11 (6-1-1); 12 (6-2-1); 13 (6-3-1); 14 (6-4-1); 15 (6-5-1) e 16 (6-6-1); b) feedforward (LM): R=0,95; 0,97; 0,96; 0,97; 0,95; 0,95; 0,96 e 0,98 e NS=0,90; 0,94; 0,92; 0,93; 0,91; 0,90; 0,91 e 0,96 para RNAs 21 (6-1-1), 22 (6-2-1), 23 (6-3-1), 24 (6-4-1), 25 (6-5-1), 26 (6-6-1), 27 (6-7-1) e 28 (6-8-1); c) base radial: R=0,99 e NS=0,98 para todas as RNAs testadas (RNA 1 a 10); verificação: a) feedforward (RP): R=0,94; 0,94; 0,92; 0,95; 0,87 e 0,87 e NS=0,90; 0,89; 0,82; 0,90; 0,63 e 0,76 para RNAs 11 a 16; b) feedforward (LM): R=0,64; 0,54; 0,58; 0,54; 0,66; 0,63; 0,61 e 0,64 e NS=0,88; 0,92; 0,90; 0,92; 0,87; 0,89; 0,89 e 0,88 para RNAs 21 a 28; c) base radial: R=0,75; 0,84; 0,89; 0,92; 0,94; 0,95; 0,95; 0,92; 0,95 e 0,94 e NS=0,56; 0,71; 0,79; 0,84; 0,89; 0,90; 0,91; 0,85; 0,90 e 0,89 para RNAs 1 (6-125-1), 2 (6-75-1), 3 (6-55-1), 4 (6-50-1), 5 (6-50-1), 6 (6-55-1), 7 (6-60-1), 8 (6-60-1), 9 (6-50-1) e 10 (6-50-1) combinações: i) R=0,96; 0,97; 0,98; 0,99; 0,99 e 0,99 e NS=0,92; 0,95; 0,99; 0,98; 0,92 e 0,90 para RNAs 31 a 36 no treinamento; R=0,94; 0,4; 0,89; 0,88; 0,92 e 0,90 e NS=0,889; 0,68; 0,71; 0,66; 0,84 e 0,82 para RNAs 31 a 36 na verificação; ii) R=0,96; 0,99; 0,99; 0,99 e 0,99 e NS=0,92; 0,98; 0,98; 0,98; 0,98 e 0,98 para RNAs 41 a 46 no treinamento; R=0,95; 0,90; 0,89; 0,92; 0,91 e 0,92 e NS=0,90; 0,78; 0,76; 0,84; 0,83 e 0,87 para RNAs 41 a 46 na verificação; iii) R=0,96; 0,98; 0,99; 0,99 e 0,99 e NS=0,92; 0,97; 0,98; 0,98 e 0,98 para RNAs 51 a 55 no treinamento; R=0,94; 0,92; 0,94; 0,94 e 0,94 e NS=0,90; 0,82; 0,87; 0,89 e 0,90 para RNAs 51 a 55 na verificação	melhor modelo RNA: 1) feedforward: RNA14 para RP e RNA22 para LM; 2) base radial: RNA7. Cenário de RNAs proposto por Sudheer et al. (2002) é a melhor combinação de entrada
Memanian e Balasundram (2012)	bacia Hulu Langat (rio Langat), Malaysia	390,26 km²	comparar o desempenho de duas redes neurais na previsão da descarga de sedimentos em suspensão	RNA de base radial e perceptron de múltiplas camadas	perceptron: retropropagativo (Gradiente de Descida)	Vazão (Q)	descarga de sedimentos suspenso (Q_s)	1997-2008: 54% dos dados para treinamento, 14% para validação cruzada e 32% para verificação	diário	R=0,812 para RNA perceptron de múltiplas camadas e 0,814 para RNA de base radial	o erro da rede perceptron de múltiplas camadas é menor na série de verificação em relação à RNA de base radial
Muhammadi, Akbari e Azizian (2012)	reservatório Karaj	832,237 km²	estimativa da descarga de sedimentos	RNA perceptron de múltiplas camadas (3 camadas), curva-chave e sistema de inferência neuro-fuzzy adaptativo (ANFIS)	método de Markowitz-Lonburch	vazão no rio, vazão de base e temperatura da água. Os dados foram usados na forma bruta e normalizados	descarga de sedimentos (Q_s)	3037 dados (1967-2007), sendo 2126 (70%) para treinamento e 911 (30%) para verificação	diário?	R=0,85 no treinamento e 0,84 na verificação para os dados de entrada na forma bruta e R=0,92 e; 0,93 no treinamento e verificação utilizando dados de entrada normalizados	-
Mustafa, Isa e Rezaur (2012)	Rio Pari (sub-bacia do rio Kinta), Silibin, Malásia Peninsular	245 km²	avaliar o desempenho de 4 algoritmos de treinamento da RNA na previsão da descarga de sedimentos suspensos	perceptron de múltiplas camadas	Gradiente de Descida (GD), Gradiente de Descida com Momento (GDM), Gradiente Conjugado Escalonado (GCE) e Levenberg Marquardt (LM)	descarga diária. Entrada: Q_t ; Q_{t-1} e Q_{t-2}	descarga de sedimentos suspensos (Q_s)	5 anos: 06/01/1993-24/10/1998, sendo 70% (06/01/1993-03/03/1997) para treinamento e 30% (04/03/1997-24/10/1998) para verificação	diário	R² (verificação): 0,9842 para GD; 0,9851 para GDM; 0,9926 para GCE e 0,9929 para LM	os algoritmos de aprendizagem GCE e LM alcançam a precisão necessária com menor número de iterações. Em termos de erro na previsão (verificação), o algoritmo GCE apresentou resultados um pouco melhores do que o LM, mas a convergência foi mais rápida para LM
Nourani, Kalantani e Baghanam (2012)	9 estações na bacia do rio Eel, Califórnia, EUA	8051 km²	desenvolver modelos para estimar a carga de sedimentos suspensos nas estações e em qualquer ponto da bacia	2 RNAs perceptron de múltiplas camadas (3 camadas)	Levenberg-Marquardt	RNA 1: testados P_t ; Q_t ; Q_{t-1} ; Q_{t-2} ; Q_{t-3} ; RNA 2: de base geomorfológica cenários: 1) 1 RNA (RNA 1) para cada estação (estação 1 a 6); 2) 1 única RNA (RNA 1) para as 6 estações (entrada: dados de todas as estações; saída: S; em cada estação); 3) RNA 2, com parâmetros geomorfológicos (área - A, perímetro - P, declividade - G e; valor CN) e hidrometeorológicos (precipitação - P, vazão - Q e; intensidade precipitação - I)	carga de sedimento suspenso (S_t)	estação 1 a 6 (RNA 1): 12/1966-09/1969 para treinamento e 10/1969-09/1970 para verificação RNA 2: 1966 a 1969 para 7 estações usado para treinamento e dados de 6 estações (1969-1970) usados para verificação	diário	cenário 1: a) estação 1: NS=0,925 e 0,862 para treinamento e verificação (5-8-1; entrada: P_t , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3}); b) estação 2: NS=0,934 e 0,761 para treinamento e verificação (5-8-1; entrada: P_t , Q_t , Q_{t-1} , Q_{t-2} , Q_{t-3}); c) estação 3: NS=0,921 e 0,841 para treinamento e verificação (4-7-1; entrada: P_t , Q_t , Q_{t-1} , Q_{t-2}); d) estação 4: NS=0,913 e 0,865 para treinamento e verificação (4-5-1; entrada: P_t , Q_t , Q_{t-1} , Q_{t-2}); e) estação 5: NS=0,930 e 0,820 para treinamento e verificação (3-6-1; entrada: P_t , Q_t , Q_{t-1}); e) estação 6: NS=0,895 e 0,790 para treinamento e verificação (3-6-1; entrada: P_t , Q_t , Q_{t-1}) cenário 2: a) treinamento: NS=0,942; 0,950; 0,940; 0,933; 0,942 e 0,940 para estações 1 a 6 (24-20-6; entrada: P_t , Q_t , Q_{t-1} , Q_{t-2} em cada estação); b) verificação: NS=0,860; 0,780; 0,840; 0,844; 0,820; 0,818 para estações 1 a 6 cenário 3: NS=0,976 e 0,882 para treinamento e verificação da RNA e NS=0,812 e 0,761 para validação cruzada estações 8 e 9. Configurações: 7-10-1; entrada: $P_{m,t}$; $Q_{m,t}^k$; A^k ; P^k ; G^k ; CN^k e I_m ; onde "k" indica variação espacial ou índice da sub-bacia; "t" indica a variação temporal ou índice de tempo dos processos e; "m" indica a variação mensal	RNA de base geomorfológica tem resultados um pouco superiores. Os resultados também foram comparados a modelos de regressão. Para estações com maior área de abrangência foi necessário introduzir mais valores de Q defasados no tempo
Shabani e Shabani (2012)	bacia de Kharwastan (rio Shoor Kharestan), Província de Fars, Irã	14685 hectares	estimativa dos sedimentos suspensos diários	RNA perceptron de múltiplas camadas (4 camadas) e curva-chave tradicional	retropropagativo (Gradiente de Descida)	vazão (Q)	descarga de sedimentos suspensos (Q_s)	25 anos: 1985-2009, sendo 80% para treinamento e 20% para verificação	diário	R²= 0,98 para configuração 1-20-7-1 e 0,74 para curva-chave	

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(Continuação)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Shiri e Kisi (2012)	estação de Trenton, rio Delaware	17560 km²	estimativa da carga diária de sedimentos suspensos por diferentes metodologias	parte i) programação de expressão genética (PEG), neuro-fuzzy e RNA (feedforward 3 camadas), regressão linear múltipla e curva chave tradicional; parte ii) comparação dos 3 primeiros (parte i) associados a transformada Wavelet	RNA feedforward: Levenberg-Marquardt	vazão (Q) e carga de sedimentos (S) cenários: 1) Q _t ; 2) S _{t-1} ; 3) Q _t e S _{t-1} ; 4) S _{t-1} e S _{t-2} ; 5) Q _t , S _{t-1} e S _{t-2} ; 6) Q _t , Q _{t-1} e S _{t-1} ; 7) Q _t , Q _{t-1} , S _{t-1} e S _{t-2}	carga de sedimento suspenso (S _t)	01/09/1949-31/03/1982: 16 anos (50% dos dados) para treinamento, 8 anos (25% dos viores) para validação cruzada e 25% (8 anos) para verificação	diário	RNA: a) validação: R²=0,578 (1-7-1); 0,237 (1-5-1); 0,640 (2-2-1); 0,409 (2-2-1); 0,735 (3-2-1); 0,822 (3-10-1) e 0,838 (4-8-1) para cenários 1 a 77; b) verificação: R²=0,817 e NS=0,736 para cenário 6 e; R²=0,821 e NS=0,734 RNA Wavelet: a) validação: R²=0,577; 0,449; 0,564; 0,613; 0,591; 0,884 e 0,879 para cenários 1 a 7; b) verificação: R²=0,898 e NS=0,886 para cenário 6 e; R²=0,897 e NS=0,890 para cenário 7	o emprego da transformada Wavelet aumenta o desempenho de todos os modelos
Singh et al. (2012)	bacia de Nagwa, estado de Jharkhand, Índia	9246 hectares	comparar os resultados da produção de sedimentos mensal utilizando SWAT e Perceptron de múltiplas camadas	RNA perceptron de múltiplas camadas (3 camadas)	retropropagativo (Gradiente de Descida)	cenários RNA: 1) Q média diária; 2) Q média diária e precipitação diária (P); 3) Q média diária; precipitação diária (P) e Q média diária do dia anterior	produção de sedimentos	1993-2004 para treinamento e 2005-2007 para verificação	mensal	R²=0,74 (1-6-1); 0,83 (2-6-1) e 0,78 (3-6-1) para cenários 1, 2 e 3. Melhor modelo: R²=0,84 e NS=0,76 no treinamento e; R²=0,77 e NS=0,74 na verificação	modelo perceptron de múltiplas camadas apresenta resultados melhores que o SWAT durante a verificação
Boukhrija et al. (2013)	bacia do rio El Kebir, Algeria	681 km²	estimar a carga de sedimentos suspensos (descarga ou concentração de sedimentos) diária e anual	2 RNA: feedforward de 3 camadas (FF) e cascata-forward (CF)	2 algoritmos testados para cada RNA: Levenberg-Marquardt (LM) e Regularização Bayesiana (RB)	vazão (Q _t , Q _{t+1} , Q _{t-1} e Q _{t-2}) e concentração de sedimentos diária (CS _{t-1} e CS _{t-2}) testadas 2 divisões dos dados: 80-10-10 e 70-15-15 (treinamento-validação-verificação)	descarga de sedimentos (Q _{st}) e/ou concentração de sedimentos (CS)	1086 dados (1975/76-1998/99): 70 a 80% usado para treinamento; 15 a 10% para validação cruzada e 15 a 10% para verificação	diário	verificação RNA FF: 1) DIVISÃO 80-10-10: a) algoritmo LM: R=0,975 e NS=0,95 (9 neurônios), R=0,978 e NS= 0,96 (12 neurônios) e; b) algoritmo RP: R=0,976 e NS=0,95 (9 neurônios), R=0,977 e NS=0,95 (12 neurônios); 2) DIVISÃO 70-15-15: a) algoritmo LM: R=0,977 e NS=0,96 (10 neurônios), R=0,979 e NS= 0,96 (12 neurônios) e; b) algoritmo RP: R=0,975 e NS= 0,95 (6 neurônios), R=0,975 e NS=0,95 (10 neurônios) RNA CF: 1) DIVISÃO 80-10-10: a) algoritmo LM: R=0,975 e NS=0,95 (9 neurônios) e; b) algoritmo RP: R=0,977 e NS=0,95 (11 neurônios), R=0,976 e NS=0,95 (12 neurônios); 2) DIVISÃO 70-15-15: a) algoritmo LM: R=0,972 e NS=0,94 (11 neurônios); b) algoritmo RP: R=0,975 e NS= 0,95 (9 neurônios), R=0,975 e NS=0,95 (12 neurônios) # Melhor resultado (considerando também o RMSE): 1) Divisão 80-10-10: RNA CF, algoritmo LM, 9 neurônios (R=0,97; 0,99 e 0,86 para treinamento, validação e verificação) e; 2) Divisão 70-15-15: RNA FF, algoritmo RP, 6 neurônios (R=0,97; 0,96 e 0,99 para treinamento, validação e verificação)	Modelos foram comparados aos resultados obtidos por curva-chave tradicional de sedimento. Melhor resultado para as entradas: Q _t , Q _{t-1} , Q _{t-2} e Q _{t-1}
Eisazadeh et al. (2013)	25 sub-bacias à montante do reservatório da província de Azerbaijan, Irã	variavam entre 29 e 1214 hectares	modelar a produção de sedimentos nas sub-bacias	perceptron de múltiplas camadas (3 camadas)	retropagativo (Gradiente de Descida)	diferentes parâmetros de clima e fatores geomorfológicos	produção de sedimentos anual	160 dados: 70% dos dados para treinamento e 30% para verificação	anual	R²=0,62 (RNA 7-5-1); 0,68 (RNA 7-10-1); 0,80 (RNA 7-15-1) e 0,86 (RNA 7-20-1) no treinamento R²=0,35 (RNA 7-5-1); 0,49 (RNA 7-10-1); 0,68 (RNA 7-15-1) e 0,73 (RNA 7-20-1) na verificação	melhor RNA: 7-20-1 (7 na neurônios camada de entrada, 20 na camada intermediária e 1 na camada de saída). Também foram testados modelos de regressão
Ghorbani et al. (2013)	rio Chama, estado do Colorado e Novo México	201 km²	estimar a carga de sedimentos suspensos diária e anual	perceptron de múltiplas camadas (3 camadas); curva chave de sedimentos; regressão linear múltipla e modelo	retropropagativo (Gradiente de Descida)	vazão e sedimentação diários. Testadas diferentes combinações de Q _t , Q _{t-1} e S _{t-1}	carga de sedimentos suspensos (S _t)	365 dados para treinamento (01/01/1994-31/12/1994) e 365 para verificação (01/01/1995-31/12/1995)	diário	-	o modelo RNA tem melhor desempenho do que os demais na simulação da carga de sedimentos diária (usando Q _t), enquanto o modelo neuro-fuzzy (usando Q _t e S _{t-1}) tem melhores resultados para a carga anual
Haddadchi et al. (2013)	bacia de Chelchay, rovincia de Golestan, Irã	272 km²	comparar 9 fórmulas para o transporte de carga suspensa com os resultados obtidos para diferentes estruturas de RNA	feedforward (3 e 4 camadas testadas) e; modelos padrões de transporte de sedimento (9 equações)	Levenberg- Marquardt	velocidade (U), profundidade de fluxo (D), inclinação leito do rio (S), tamanho mediano de sedimentos do material do leito d _{50-bm} , carga do leito (Q _b) e tamanho médio do sedimento da carga suspensa (d _{50-s}) cenários: 1) U, D, S, Q _b , d _{50-bm} , d _{50-s} ; 2) U, D, S, d _{50-bm} , d _{50-s} ; 3) U, D, S, d _{50-bm}	descarga de sedimentos suspensos (Q _b)	-	-	R= 0,99 no treinamento, para todos os cenários de RNAs investigados verificação: a) cenário 1: R= 0,75 (RNA 6-5-1); 0,74 (RNA 6-12-1); 0,73 (RNA 6-2-2-1) e; 0,63 (RNA 6-2-4-1); b) cenário 2: R=0,83 (RNA 5-6-1); 0,78 (RNA 5-18-1); 0,73 (RNA 5-2-1-1) e; 0,75 (RNA 5-1-3-1) e; c) cenário 3: 0,87 (RNA 4-4-1); 0,82 (RNA 4-11-1); 0,91 (RNA 4-4-1-1); 0,80 (RNA 4-1-2-1) e; 0,77 (RNA 4-2-2-1)	os resultados foram comparados com fórmulas propostas por: Van Rijn (1984); Bagnold (1966); Bijker (1971); Einstein (1950); Engelund (1976); Lane- Kalinske (1941); Samaga (1986); Brooks (1963) e Chang et al. (1965) foram testadas RNAs com 3 e 4 camadas, variando o n° de neurônios na camada intermediária relação neurônios melhor RNA cenário 3): 4-4-1-1 e 4-4-1
Kazemzadeh, Ayyoubzadeh e Monidnezhad (2013)	estuário Bahmanshir, Irã	156 m² (região observada)	analisar a CSS, através da simulação da relação entre CSS e reflectância da superfície (imagens MODIS)	feedforward (3 camadas)	Levenberg- Marquardt	reflectância atmosférica corrigida, obtida pelo produto MODIS (surface reflectance product - MOD09GQ). Utilizadas bandas 1 e 2	CSS _t	5 campanhas para coleta CSS (25/04/2003-11/06/2003) - 29 dados 9 anos de dados MODIS (2003-2011) - 442 imagens 23 dados de CSS para treinamento e 6 para verificação	-	R² = 0,84 no treinamento e 0,93 na verificação	RMS=59 mg/L na verificação. Os resultados da RNA foram comparados com modelo de regressão
Lafdane, Nia e Ahmadi (2013)	bacia do rio Doiraj, Irã	-	prever a carga de sedimentos suspensos	RNA (feedforward), máquina de vetores de suporte	retropropagativo Gradiente Conjugado (GC) e algoritmo BFGS	vazão (Q) e precipitação (P). RNA - cenários definidos por coeficiente de correlação (CC): 1) Q _t , P _t , Q _{t-1} , P _{t-1} , Q _{t-2} , Q _{t-3} , Q _{t-4} ; 2) Q _t , P _t , Q _{t-1} ; 3) Q _t , Q _{t-1} , Q _{t-2} , Q _{t-3} , Q _{t-4} ; 4) Q _t , P _t , Q _{t-1} , Q _{t-2} RNA - cenários definidos por Gama Teste (GT) e Algoritmo Genético (AG): melhor escolha = Q _t , P _t , Q _{t-1} , P _{t-1} , Q _{t-2} , P _{t-2}	descarga de sedimentos suspensos - Q _{st} (t)	11 anos: 1994-2004	diário	BFGS: a) treinamento: R²=0,987; 0,996; 0,997; 0,995 para cenários 1, 2, 3 e 4 escolhidos por CC e R²=0,999 para cenário escolhido por GT-AG; b) verificação: R²= 0,973; 0,969; 0,981 e 0,978 para cenários testados 1, 2, 3 e 4 escolhidos por CC e R²=0,998 para cenário escolhido por GT-AG GC: a) treinamento: R²= 0,986; 0,995; 0,997 e 0,994 para cenários 1, 2, 3 e 4 escolhidos por CC e R²=0,999 para cenário escolhido por GT-AG; b) verificação: R²=0,971; 0,974; 0,978 e 0,979 para cenários testados 1, 2, 3 e 4 escolhidos por CC e R²=0,975 para cenário escolhido por GT-AG	menor erro para cenário definido por GT-AG e algoritmo de treinamento BFGS

Tabela 47 - Descrição de estudos que utilizaram RNAs para cálculos hidrossedimentológicos

(fim)

Autor	Local	Área da bacia/ área analisada	Objetivo	Características modelo	Algoritmo de treinamento	Variáveis de entrada	Variáveis de saída	Período de dados/ N° de registros	Intervalo de tempo	NS/R²/R	Outras observações/conclusões
Liu et al. (2013)	bacia do rio Kuyue, China	8706 km²	analisar a capacidade da RNA Wavelet prever a CSS em escoamento superconcentrado e; comparar os resultados com métodos tradicionais de curva-chave e RNA	RNA Wavelet, RNA feedforward (3 camadas) e curva-chave tradicional	RNA feedforward: retropropagativo (Gradiente de Descida)	vazão (Q) e CSS cenários RNA (feedforward): 1) Q _t , Q _{t-1} , CSS _{t-1} ; 2) Q _t , Q _{t-1} , CSS _{t-1} , CSS _{t-2} cenários RNA Wavelet: 3) Q _t , Q _{t-1} , CSS _{t-1} ; 4) Q _t , Q _{t-1} , CSS _{t-1} , CSS _{t-2} , onde o símbolo "r" indica que a série original foi reconstruída (pré-processamento Wavelet)	CSS _t	2193 dias: 1967-1972, sendo 1461 valores (1967-1970) para treinamento, 365 (1971) para validação cruzada e 366 valores (1972) para verificação	diário	RNA feedforward: a) treinamento: R²=0,588; 0,627; 0,616 e 0,567 para 4, 5, 6 e 7 neurônios no cenário 1 e; R²=0,613; 0,608; 0,646 e 0,599 para 4, 5, 6 e 7 neurônios no cenário 2; b) validação cruzada: R²=0,658; 0,629; 0,629 e 0,664 para 4, 5, 6 e 7 neurônios no cenário 1 e; R²=0,651; 0,646; 0,651 e 0,612 para 4, 5, 6 e 7 neurônios no cenário 2; c) verificação: R²=0,658; 0,629; 0,629 e 0,664 pra 4, 5, 6 e 7 neurônios no cenário 2 e; R²= 0,651; 0,646; 0,651 e 0,612 para 4, 5, 6 e 7 neurônios no cenário 2 RNA Wavelet: a) treinamento: R²=0,629; 0,599; 0,581 e 0,619 para 4, 5, 6 e 7 neurônios no cenário 3 e; R²=0,712; 0,661; 0,729 e 0,607 para 4, 5, 6 e 7 neurônios no cenário 4; b) verificação: R²=0,832; 0,797; 0,773 e 0,817 para 4, 5, 6 e 7 neurônios no cenário 3 e; R²=0,806; 0,721; 0,848 e 0,776 para 4, 5, 6 e 7 neurônios no cenário 4; c) verificação: R²=0,830; 0,797; 0,771 e 0,817 para 4, 5, 6 e 7 neurônios no cenário 3 e; R²=0,805; 0,717; 0,846 e 0,776 para 4, 5, 6 e 7 neurônios no cenário 4	cenário 1: modelo com 6 neurônios é o melhor cenário 2: modelo com 4 neurônios é o melhor
Salimi et al. (2013)	reservatório de Karaj (Amirkabir), rio Karaj, Irã. Foram monitoradas 2 estações, à montante (Seera) e à jusante (Beylaghan)	850 km²	estimar o volume de sedimentos retidos no reservatório	RNA feedforward (3 camadas)	retropropagativo: Gradiente de Descida com aprendizado adaptativo (GDA); Gradiente de Descida com Momento (GDM); Levenberg Marquardt (LM) e; um método de secante em um passo	precipitação (P), fluxo de entrada no reservatório (I), fluxo de saída do reservatório (O)	volume anual de sedimentos retido no reservatório (Vs)	32 anos (1980-2011): 72% (23 anos) para treinamento e 28% (9 anos) para verificação	anual	R²=0,9716 no treinamento e R²=0,9882 na verificação para algoritmo LM e configuração 3-3-1	
Singh et al. (2013)	bacia de Nagwa, distrito de Hazaribagh, Índia	9246 hectares	estimativa da produção de sedimentos mensal utilizando 2 tipos de RNAs	RNA feedforward padrão (perceptron de múltiplas camadas - 3 camadas) e RNA de base radial	RNA feedforward: retropropagativo (Gradiente de Descida)	precipitação mensal (P _t), vazão média mensal (Q _t) cenários: 1) Q _t ; 2) P _t e Q _t ; 3) P _t , Q _t e Q _{t-1} ; 4) Q _t , P _t , Q _{t-1} e Q _{t-2}	produção de sedimentos	1991-2007: período de junho a outubro dos anos de 1991-2004 para treinamento (70% dos dados) e 2001-2007 para verificação (30% dos dados)	mensal	RNA de base radial: R²=0,72 e R=0,80 (1-6-1) para cenário 1, R²=0,81 e R=0,90 (2-6-1) para cenário 2, R²=0,77 e R=0,86 (3-6-1) para cenário 3 e; R²=0,76 e R=0,86 (4-6-1) para cenário 4 Melhor modelo - cenário 2: a) RNA base radial: R²=0,82 e NS=0,76 no treinamento e R²=0,77 e NS=0,74 na verificação; b) RNA feedforward: R²=NS=0,90 no treinamento e R²=0,88 e NS=0,83 na verificação	
Bayram et al. (2014)	sub-bacia de Harsit (bacia de Eastern Black Sea), Turquia. Foram monitoradas 6 estações	24077 km²	estimar a CSS a partir de variáveis de qualidade da água (cromo, ferro e turbidez)	feedforward (3 camadas)	retropropagativo (Gradiente de Descida)	concentração total de cromo (Cr), concentração total de ferro (Fe) e turbidez (T) modelos testados (entradas): M1) T; M2) Cr; M3) Fe; M4) T e Cr; M5) T e Fe; M6) Fe e Cr; M7) T, Cr e Fe	CSS _t	132 dados: 96 para treinamento, 24 para validação e 12 para verificação período: 04/2009 e 02/2010	quinzenal		RNA tem bons resultados para prever CSS. Melhor modelo M7, sendo RMSE=20,38 e EaM=11,67 mg/L para a validação e RMSE=13,05 e EaM=10,29 mg/L na verificação. Resultados foram comparados aqueles obtidos por análise de regressão validação (mg/L): RMSE variou entre 20,38 para M7 e 22,71 para M3; EaM variou entre 11,55 para M6 e 15,18 para M4 verificação (mg/L): RMSE variou entre 9,78 para M1 e 28,83 para M2; EaM variou entre 6,44 para M1 e 25,10 para M2
Afan et al. (2015)	bacia do rio Johor (Malásia Peninsular)	2286 km²	determinar a carga diária de sedimentos (S), a partir de dados de sedimento e vazão de dias anteriores	2 RNAs (3 camadas): RNA feedforward e RNA de base radial	retropropagativo (Gradiente de Descida) para RNA feedforward	vazão (Q) e carga de sedimento diária (S) - testados 2 cenários e 5 tipos de entrada *cenário I: 1) S _{t-1} ; 2) S _{t-1} , S _{t-2} ; 3) S _{t-1} , S _{t-2} , S _{t-3} ; 4) S _{t-1} , S _{t-2} , S _{t-3} , S _{t-4} ; *cenário 2: 1) S _{t-1} , Q _{t-1} ; 2) Q _{t-1} , S _{t-1} , S _{t-2} ; 3) Q _{t-1} , Q _{t-2} , S _{t-1} ; 4) Q _{t-1} , Q _{t-2} , S _{t-1} , S _{t-2} ; 5) Q _{t-1} , Q _{t-2} , S _{t-1} , S _{t-2} , S _{t-3}	S _t	11 anos: 01/01/1988 a 31/12/1998 (4018 dados diários) 10 anos treinamento: 3653 dados 1 ano verificação: 365 dados	diário (dados de 1, 2 e 3 dias anteriores)	cenário I: R²=0,892; 0,903; 0,894 e 0,891 para as situações 1, 2, 3 e 4 da RNA feedforward e R²=0,897; 0,899; 0,877 e 0,880 para situações 1, 2, 3 e 4 da RNA de base radial cenário II: R²=0,894; 0,904; 0,892; 0,926 e 0,899 para a RNA feedforward e R²=0,894; 0,893; 0,899; 0,909 e 0,892 para RNA de base radial	cenário I: melhores resultados para a situação 3 (S _{t-1} , S _{t-2} , S _{t-3}). Critério considerado RMSE e EAM cenário II: melhor resultado situação 4 (Q _{t-1} , Q _{t-2} , S _{t-1} , S _{t-2}) A RNA feedforward apresenta melhores resultados em relação a RNA de base radial. Cenário II tem melhores resultados que o cenário I
Nourani e Adalib (2015)	bacia do rio Mississippi, EUA	1847180 km²	modelar a relação vazão-sedimentos, inclusive para diferentes passos de tempo a frente (1, 2, 5 e 7 dias)	Wavelet Least Square Support Vector Machines; RNA (feedforward - 3 camadas); RNA wavelet	retropropagativo (Gradiente de Descida)	vazão (Q) diária e mensal e a carga de sedimentos suspensos (S). Para os modelos que envolvem transformada Wavelet Q e S foram decompostos em sub-sinais em vários níveis de resolução, sendo utilizados como entrada cenários RNA feedforward: 1) S _{t-1} ; 2) Q _{t-1} ; 3) Q _{t-1} e S _{t-1} ; 4) S _{t-1} ; S _{t-2} ; Q _{t-1} e Q _{t-2} ; 5) S _{t-1} ; S _{t-2} ; S _{t-3} ; Q _{t-1} ; Q _{t-2} e Q _{t-3} ; 6) S _{t-1} ; S _{t-2} ; S _{t-3} ; S _{t-4} ; Q _{t-1} ; Q _{t-2} ; Q _{t-3} e Q _{t-4} ; 7) S _{t-1} ; S _{t-2} ; S _{t-12} ; Q _{t-1} e Q _{t-12}	carga de sedimentos suspensos (S) diária e mensal (tempo t e previsão a frente)	75% para treinamento e 25% para verificação	diário e mensal	RNA feedforward: a) diário: NS=0,91; 0,65; 0,91; 0,95; 0,95 e 0,96 no treinamento NS=0,85; 0,44; 0,84; 0,88; 0,87 e 0,87 na verificação, considerando as entradas dos cenários 1 a 7; b) mensal: NS=0,41; 0,37; 0,52 e 0,74 no treinamento e NS=0,38; 0,34; 0,45 e 0,72; considerando as entradas dos cenários 1, 2, 3 e 7; c) previsão a frente: NS=0,95; 0,85; 0,52 e 0,41 para 1, 2, 5 e 7 dias no treinamento e NS=0,88; 0,72; 0,37 e 0,21 para 1, 2, 5 e 7 dias na verificação RNA Wavelet: a) entrada decomposta: NS=0,80 no treinamento e 0,75 na verificação; b) previsão a frente: NS=0,95; 0,89; 0,75 e 0,55 para 1, 2, 5 e 7 dias no treinamento e NS=0,95; 0,85; 0,68 e 0,55 para 1, 2, 5 e 7 dias na verificação	melhor cenário RNA feedforward: cenário 4 (usado para testes de previsão em dias a frente)
Olyai et al. (2015)	2 estações: i) rio Flathead, Flathead British Columbia, Montana, EUA e; ii) rio Santa Clara, Califórnia, EUA	Flathead: 427 milhas² Santa Clara: 1600 milhas²	estimativa da carga diária de sedimentos suspensos usando RNA, RNA Wavelet e ANFIS e comparação com curva-chave tradicional	RNA perceptron de múltiplas camadas (3 camadas), curva-chave, RNA Wavelet e sistema de inferência neuro-fuzzy adaptativo (ANFIS)	retropropagativo (Gradiente de Descida)	vazão (Q) e carga de sedimentos suspensos (S). Testados 1 a 6 neurônios na camada intermediária para RNA e 1 a 7 neurônios para RNA Wavelet cenários: 1) S _{t-1} ; 2) S _{t-1} e Q _{t-1} ; 3) S _{t-1} e Q _{t-1} ; 4) S _{t-1} ; Q _{t-1} e Q _{t-1} ; 5) S _{t-1} ; S _{t-2} ; Q _{t-1} e Q _{t-1}	carga de sedimentos suspensos diária (S)	6 anos ou 75% dos dados para treinamento e 2 anos ou 25% dos dados para verificação Flathead: (01/10/1975-30/09/1981) para treinamento e (01/10/1981-30/09/1983) para verificação Santa Clara: 01/10/1968-30/09/1974 para treinamento e 01/10/1974-30/09/1976 para verificação	diário	resultados período de verificação Flathead: a) RNA: R=0,526; 0,743; 0,662; 0,634; 0,810 e 0,813 e NS=0,378; 0,592; 0,543; 0,457; 0,649 e 0,647; considerando cenários de entradas 1 a 6; b) RNA Wavelet: R=0,775; 0,910; 0,872; 0,833; 0,959 e 0,953 e NS=0,657; 0,795; 0,738; 0,702; 0,867 e 0,829; considerando cenários de entradas 1 a 6 Santa Clara: a) RNA: R=0,646; 0,859; 0,742; 0,707; 0,877 e 0,781 e NS=0,402; 0,716; 0,634; 0,584; 0,749 e 0,635; considerando 1 a 6 neurônios; b) RNA Wavelet: R=0,791; 0,926; 0,890; 0,863; 0,961 e 0,963 e NS=0,720; 0,803; 0,797; 0,762; 0,50 e 0,844; considerando cenários de entrada 1 a 6	Flathead: i) melhor modelo RNA e RNA Wavelet para combinação 5 (erros menores) e maior NS da RNA para cenário 6 de entradas Santa Clara: melhor modelo RNA e RNA Wavelet para cenário 5 de entradas

* apresentados apenas resultados com dados coletados em campo. Não foram mostrados os dados de laboratório e associação campo + laboratório

Fonte: autora