

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

LAÍS COELHO TEIXEIRA

ESTIMATIVA DA PRODUÇÃO DE SEDIMENTOS EM SUSPENSÃO COM
MODELOS DE REDES NEURAS ARTIFICIAIS E AVALIAÇÃO DE IMPACTOS EM
CENÁRIOS FUTUROS DECORRENTES DE MUDANÇAS CLIMÁTICAS -
APLICAÇÃO NA BACIA DO RIO POTIRIBU NO NOROESTE DO ESTADO DO RIO
GRANDE DO SUL.

PORTO ALEGRE

2022

LAÍS COELHO TEIXEIRA

ESTIMATIVA DA PRODUÇÃO DE SEDIMENTOS EM SUSPENSÃO COM
MODELOS DE REDES NEURAIAS ARTIFICIAIS E AVALIAÇÃO DE IMPACTOS EM
CENÁRIOS FUTUROS DECORRENTES DE MUDANÇAS CLIMÁTICAS -
APLICAÇÃO NA BACIA DO RIO POTIRIBU NO NOROESTE DO ESTADO DO RIO
GRANDE DO SUL.

Tese apresentada ao Programa de Pós-graduação
em Recursos Hídricos e Saneamento Ambiental da
Universidade Federal do Rio Grande do Sul, como
requisito parcial à obtenção do grau de doutor (a).

Orientador: Prof. Dr. Olavo Correa Pedrollo

Coorientadora: Prof. Dr.^a Nilza Maria dos Reis
Castro

PORTO ALEGRE

2022

CIP - Catalogação na Publicação

Teixeira, Laís Coelho

Estimativa da produção de sedimentos em suspensão com modelos de redes neurais artificiais e avaliação de impactos em cenários futuros decorrentes de mudanças climáticas - aplicação na bacia do rio potiribu no noroeste do estado do Rio Grande do Sul. / Laís Coelho Teixeira. -- 2022.

177 f.

Orientador: Olavo Correa Pedrollo.

Coorientadora: 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, 2022.

1. precipitação homogênea. 2. modelo climático regional Eta-HadGEM2-ES. 3. múltipla-escala. 4. mudanças climáticas. 5. correção de viés. I. Pedrollo, Olavo Correa, orient. II. Castro, Nilza Maria dos

Reis, coorient. III. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

LAÍS COELHO TEIXEIRA

ESTIMATIVA DA PRODUÇÃO DE SEDIMENTOS EM SUSPENSÃO COM
MODELOS DE REDES NEURAIS ARTIFICIAIS E AVALIAÇÃO DE IMPACTOS EM
CENÁRIOS FUTUROS DECORRENTES DE MUDANÇAS CLIMÁTICAS -
APLICAÇÃO NA BACIA DO RIO POTIRIBU NO NOROESTE DO ESTADO DO RIO
GRANDE DO SUL.

Tese apresentada ao Programa de Pós-graduação
em Recursos Hídricos e Saneamento Ambiental da
Universidade Federal do Rio Grande do Sul, como
requisito parcial à obtenção do grau de doutor (a).

Aprovado em: Porto Alegre, 07 de outubro de 2022.

Prof. Dr. Olavo Correa Pedrollo – UFRGS/IPH
Orientador

Prof. Dr.^a Nilza Maria dos Reis Castro – UFRGS/IPH
Coorientadora

Prof.^a. Dr.^a. Vanessa Sari – UFSM
Examinadora

Prof. Dr. Guilherme Garcia de Oliveira – UFRGS
Examinador

Prof. Dr. Gean Paulo Michel – UFRGS/IPH
Examinador

Dedico, aos meus queridos e amados pais,
José Cláudio e Lizete, ao meu amado
esposo Fernando, aos meus amados irmãos
Cláudia, Marília, Paula e Bruno, que foram a
base na minha caminhada. Sem o apoio de
vocês eu não conseguiria.

AGRADECIMENTOS

Agradeço à minha família pelo apoio, carinho e paciência neste momento de minha vida.

Ao meu esposo pelo carinho, amizade, apoio e muita paciência por me aguentar neste momento de minha vida.

Aos meus professores Nilza Maria dos Reis Castro, Olavo Corrêa Pedrollo pelos ensinamentos, orientação, apoio e compreensão ao longo do desenvolvimento do trabalho.

A minha colega, amiga e irmã de doutorado Priscila Mariani pelo apoio, pelos desabafos nas dificuldades, na partilha de conhecimento ao longo do desenvolvimento do trabalho.

Ao grupo de pesquisa, AHRNA - Aplicações hidroambientais com redes neurais artificiais, em especial aos colegas Juliano Finck e Luísa Lucchese, pelo apoio, amizade e pela partilha de conhecimentos ao longo do desenvolvimento do trabalho.

Aos técnicos do Instituto de Pesquisas Hidráulicas (IPH) e laboratório de sedimentos do IPH pelo apoio às atividades de campo e disponibilidade de dados para a elaboração deste trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pela bolsa, Edital/Chamada: GM/GD Cotas do Programa de Pós-Graduação, concedida para o desenvolvimento desta pesquisa.

Aos professores do Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas (IPH) pelos ensinamentos ministrados no curso.

À Universidade Federal do Rio Grande do Sul (UFRGS) e Instituto de Pesquisas Hidráulicas (IPH) pela oportunidade de realizar o doutorado na área de Recursos Hídricos e Saneamento Ambiental.

RESUMO

TEIXEIRA, Laís Coelho. Estimativa da produção de sedimentos em suspensão com modelos de redes neurais artificiais e avaliação de impactos em cenários futuros decorrentes de mudanças climáticas - aplicação na bacia do rio Potiribu no noroeste do estado do Rio Grande do Sul. 2022. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) — Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande Sul, Porto Alegre, 2022.

Os processos de erosão, de transporte e de deposição do solo vêm sendo intensificados, gerando alteração significativa na dinâmica hidrossedimentológica em escala global e local. Esse processo é influenciado por fatores como clima, características fisiográficas da bacia, uso e manejo do solo. As mudanças climáticas também podem ser fatores importantes no processo erosivo, pois a tendência no futuro é ter mudanças nos padrões das precipitações podendo impactar nessa dinâmica hidrossedimentológica. As principais consequências indesejadas possíveis são o assoreamento de rios e reservatórios, degradação das águas superficiais e inundações. A simulação dos processos hidrossedimentológicos pode contribuir para a compreensão da dinâmica desses processos, bem como para a sua previsibilidade, a qual pode ser útil para o adequado manejo e uso do solo em bacias hidrográficas agrícolas. O objetivo desta pesquisa é avaliar a variação da produção de sedimentos em suspensão (PSS) em dois cenários de mudanças climáticas futuras, para bacias agrícolas de diferentes escalas, utilizando um modelo integrado em uma única rede neural artificial (RNA) para estimativas da produção de sedimentos em suspensão. A metodologia consiste em três etapas: 1 – monitoramento: caracterização da área de estudo, métodos de medição para a obtenção dos dados observados como precipitação, concentração de sedimentos em suspensão e vazão, e análise e as consistências destes dados; 2- cenário atual: foi desenvolvido um modelo baseado em RNAs integrando dados de diferentes escalas de bacias (regional) com diferentes combinações de variáveis de entrada (precipitações antecedentes – P0, .., P7; filtro gama das precipitações medidas, regional, e filtro gama das precipitações medidas, individual por bacia; área da bacia) para estimar PSS, treinado para o período de 1990 a 2020 com intervalo tri-horário; 3- cenário futuro: aplicação do melhor modelo de RNAs para estimar a PSS em dois cenários climáticos futuros (RCP 4.5 e 8.5) projetados para o período de 2021 a 2099 comparando com o período observado (1990 a 2020), utilizando como entrada a série de precipitação no futuro dos dois cenários climáticos simulados pelo modelo climático regional Eta-HadGEM2-ES CPTEC/INPE. Estes dados simulados foram corrigidos pelo método de correção do viés proposto nesta pesquisa e chamado de Lehner modificado. O melhor modelo resultou da aplicação, como entradas, da área e das precipitações tri-horárias, com até seis intervalos antecedentes, com coeficiente de Nash-Suitcliffe para a série de verificação igual a 0,963, Pbias igual a -2,91 e erro absoluto médio igual a 723,8 kg/s. Resultou maiores valores de PSS no futuro para a maioria dos cenários climáticos (RCP 4.5 e RCP 8.5) para todas as bacias, comparados ao período observado nos meses de maio a dezembro, com aumento variando de 4,4% a 122,7%. Nesta pesquisa pode-se verificar que a mudança climática influencia na variação da PSS nas bacias agrícolas. Modelos empíricos do tipo das RNAs podem ser utilizados para avaliar a produção de sedimentos em suspensão, com base em resultados de modelos climáticos, para cenários futuros. Para a superação da dificuldade imposta pela escassez de dados, modelos de RNAs regionais (com integração de bacias de diferentes escalas) podem constituir-se em um recurso importante, capaz de proporcionar viabilidade às pesquisas.

Palavras-chave: precipitação homogênea, modelo climático regional Eta-HadGEM2-ES, múltipla-escala, mudanças climáticas, correção de viés.

ABSTRACT

TEIXEIRA, Laís Coelho. Estimation of suspended sediment production with models of artificial neural networks and evaluation of impacts in future scenarios due to climate change - application in the Potiribu river basin in the northwest of the state of Rio Grande do Sul. 2022. Master's thesis (Water Resources and Environmental Engineering) — Instituto de Pesquisas Hidráulicas. Universidade Federal do Rio Grande do Sul. 2022

Soil erosion, transport and deposition processes have been intensified, generating significant changes in the hydro-sedimentological dynamics on a global and local scale. This process is influenced by factors such as climate, physiographic characteristics of the basin, soil use and management. Climate change can also be one of the important factors in the erosion process, as the trend in the future is to have changes in rainfall patterns that may impact this hydro-sedimentological dynamic. The main possible unwanted consequences are the silting up of rivers and reservoirs, surface water degradation and flooding. The simulation of hydro-sedimentological processes can contribute to the understanding of the dynamics of these processes, as well as to their predictability, which can be useful for the adequate management and use of the soil in agricultural watersheds. The objective of this research is to evaluate the variation in the production of suspended sediments in two scenarios of future climate changes, for agricultural basins of different scales, using an integrated model in a single ANN to estimate the production of suspended sediments. The methodology consists of three stages: 1 – monitoring: characterization of the study area, measurement methods for obtaining observed data such as precipitation, concentration of suspended sediments and flow, and analysis and consistency of these data; 2- current scenario: a model based on ANNs was developed integrating data from different basin scales (regional) with different combinations of input variables (antecedent precipitation – P0, ..., P7; gamma filter of measured precipitation, regional, and filter range of measured rainfall, individual by basin; basin area) to estimate PSS, trained for the period 1990 to 2020 with a three-hour interval; 3- future scenario: application of the best ANN model to estimate the PSS in two future climate scenarios (RCP 4.5 and 8.5) projected for the period from 2021 to 2099 compared to the observed period (1990 to 2020), using as input the series of precipitation in the future of the two climate scenarios simulated by the regional climate model Eta-HadGEM2-ES CPTEC/INPE. These simulated data were corrected by the bias correction method proposed in this research and called modified Lehner. The best model resulted from the application as inputs, area and three-hour precipitation, with up to six antecedent intervals, with NS for verification series equal to 0.963, Pbias equal to -2.91 and Mea equal to 723.8 kg/s . It resulted in higher PSS values in the future for most climate scenarios (RCP 4.5 and RCP 8.5) for all basins compared to the period observed in the months of May to December with an increase ranging from 4.4% to 122.7%. In this research it can be seen that climate change influences the PSS variation in agricultural basins. Empirical models, such as ANNs, can be used to evaluate the production of suspended sediments, based on the results of climate models, for future scenarios. To overcome the difficulty imposed by the scarcity of data, models of regional ANNs (with integration of basins of different scales) can constitute an important resource, capable of providing viability to research.

Keywords: homogeneous precipitation. Regional climate model Eta-HadGEM2-ES CPTEC/INPE. Climate change. Bias correction.

LISTA DE ILUSTRAÇÕES

Figura 1 – Efeito splash em uma superfície plana (a) e inclinada (b).....	25
Figura 2 – Formação detalhada de voçoroca.	25
Figura 3- Formas de deslocamento e transporte dos sedimentos nos cursos d'água.	26
Figura 4 – Representação de dois hidrogramas A e B a partir de uma chuva efetiva.	28
Figura 5- Formas diferentes do comportamento da onda de sedimentos em relação a vazão: a) Pico de carga sólida se atrasando em relação ao pico da vazão; b) Pico de descarga e de carga sólida acontecendo simultaneamente; c) Pico de carga sólida se antecipa ao pico de vazão.	30
Figura 6 – Emissões de gases de efeito estufa do Brasil de 1990 a 2020 (GtCO ₂ e).	36
Figura 7 – Estimativas de emissões de CO ₂ e GWP por setor no Brasil em 2020*...37	
Figura 8 – Porcentagem dos municípios da região Sul do Brasil onde o setor é mais emissor.	37
Figura 9 - Três grandes regiões brasileiras são destacadas nos resultados: Norte (NO- verde), Nordeste (NE-vermelho) e Centro-Sul (CSblue) do Brasil.....	47
Figura 10 – Resolução espacial do modelo regional Eta de 20 km.....	47
Figura 11 - Representação do funcionamento do neurônio de McCulloch e Pitts, Σ (soma ponderada das entradas, $f(u)$ é a função de ativação e Θ é o limiar de ativação do neurônio.	56
Figura 12 – Exemplificação da classificação de padrões linearmente separáveis (A) e não-linearmente separáveis (b).	57
Figura 13 – Fluxograma das etapas da metodologia da pesquisa.	67
Figura 14 – Mapa de localização das bacias hidrográficas em estudo.	69
Figura 15 – Mapa de uso e ocupação do solo das bacias hidrográficas em estudo do ano de 2020.....	71
Figura 16 – Mapa de classificação do solo das bacias hidrográficas em estudo.	72
Figura 17 – Mapa de declividade das bacias hidrográficas em estudo.	74

Figura 18- Normais climatológicas do Brasil, precipitação acumulada anual (mm) no período de 1991 a 2020 registrado pelas estações climatológicas do Instituto Nacional de Meteorologia (INMET).....	75
Figura 19 – Comparativo das precipitações acumuladas (mm) entre os períodos históricos 1931-1960, 1961-1990 e 1991-2020 da Estação Climática de Cruz Alta do Instituto Nacional de Meteorologia – INMET.....	76
Figura 20 - Exemplificação da projeção da imagem do modelo climático regional Eta CPTEC/INPE com resolução espacial de 20 Km.	90
Figura 21 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_1.....	101
Figura 22 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_9.....	102
Figura 23 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_10.....	102
Figura 24 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_11.....	103
Figura 25 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_19.....	103
Figura 26- PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_20.....	104
Figura 27- PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos	

	valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_21.....	104
Figura 28 -	PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_27.....	105
Figura 29 -	PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_28.....	105
Figura 30 -	PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_37.....	106
Figura 31 -	PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_46.....	106
Figura 32 -	PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_53.....	107
Figura 33 –	Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Potiribu para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.	110
Figura 34 -	Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Potiribu para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.	111
Figura 35 -	Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Cambará para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.....	112
Figura 36-	Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Cambará para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.....	113

Figura 37 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Taboão para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.	114
Figura 38 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Taboão para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.	115
Figura 39- Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Turcato para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.	116
Figura 40 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Turcato para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.....	117
Figura 41 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Alemão para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.....	118
Figura 42 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Alemão para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.....	119
Figura 43 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Donato para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.....	120
Figura 44-Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Donato para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.....	121
Figura 45 – Série observada da precipitação preenchida com médias sazonais (linha vermelha) no período de 1990 a 2020.....	122
Figura 46 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Potiribu no período de 1990 a 2020.	123
Figura 47 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Cambará no período de 1990 a 2020.....	123
Figura 48 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Taboão no período de 1990 a 2020.	124
Figura 49 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Alemão no período de 1990 a 2020.	124

Figura 50 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Donato no período de 1990 a 2020.....	125
Figura 51- Resultado da FAC e da FACP dos dados de precipitação no período observado de 1990 a 2020.....	125
Figura 52- Resultado da FAC e da FACP da série de PSS da bacia do Potiribu no período observado de 1990 a 2020.....	126
Figura 53- Resultado da FAC e da FACP da série de PSS da bacia do Cambará no período observado de 1990 a 2020.....	126
Figura 54 - Resultado da FAC e da FACP da série de PSS da bacia do Taboão no período observado de 1990 a 2020.....	126
Figura 55- Resultado da FAC e da FACP da série de PSS da bacia do Turcato no período observado de 1990 a 2020.....	127
Figura 56- Resultado da FAC e da FACP da série de PSS da bacia do Alemão no período observado de 1990 a 2020.....	127
Figura 57 - Resultado da FAC e da FACP da série de PSS da bacia do Donato no período observado de 1990 a 2020.....	127
Figura 58 - Periodograma da série de precipitação no período observado (1990 a 2020).	128
Figura 59 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Potiribu.....	129
Figura 60 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Cambará.	129
Figura 61 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Taboão.....	129
Figura 62 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Turcato.....	130
Figura 63 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Alemão.....	130
Figura 64 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Donato.	130
Figura 65 – Comparativo entre as médias sazonais da PSS de cada bacia e a média sazonal da precipitação em zero no período observado (1990 a 2020).	131
Figura 66 – Matriz de correlação entre as séries de PSS mensal e a série de precipitação mensal no período de 1990 a 2020.....	132

Figura 67 – Gráfico da dispersão da precipitação em função da PSS da bacia do Potiribu.	132
Figura 68 - Gráfico da dispersão da precipitação em função da PSS da bacia do Cambará.....	133
Figura 69 - Gráfico da dispersão da precipitação em função da PSS da bacia do Taboão.	133
Figura 70 - Gráfico da dispersão da precipitação em função da PSS da bacia do Turcato.	133
Figura 71 Gráfico da dispersão da precipitação em função da PSS da bacia do Alemão.	134
Figura 72 - Gráfico da dispersão da precipitação em função da PSS da bacia do Donato.....	134
Figura 73 – Comparação das séries de precipitação mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082).	136
Figura 74 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Potiribu.....	139
Figura 75 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Cambará.....	140
Figura 76 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Taboão.....	141
Figura 77- Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Turcato.....	142
Figura 78 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e	

RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Alemão.....	143
Figura 79 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Donato.	144
Figura 80 – Média mensal da produção de sedimentos em suspensão (kg/s) simulados para todos os cenários climáticos da bacia do potiribu.	146
Figura 81 – Média mensal da Produção de sedimentos em suspensão e da precipitação para todos os cenários climáticos e para todas as bacias.	148
Figura 82 - Média mensal da Produção de sedimentos em suspensão e da precipitação para todos os cenários climáticos e para todas as bacias.	149
Figura 83 - Resultados de PSS e Precipitação no período observado (1990 a 2020) para as diferentes escalas de bacia.	170
Figura 84 - Resultados de PSS e Precipitação no cenário RCP4.5 (2021-2099) para as diferentes escalas de bacia.	171
Figura 85- Resultados de PSS e Precipitação no cenário RCP8.5 (2021-2099) para as diferentes escalas de bacia.	174

LISTA DE TABELAS

Tabela 1 - Influência relativa dos gases de efeito estufa no efeito estufa natural da atmosfera da Terra (coluna do meio) e crescimento das concentrações atmosféricas devido às emissões antropogênicas para CO ₂ , CH ₄ e N ₂ O nos anos de 2012 e 2020.....	33
Tabela 2 – Média anual global das emissões dos principais gases do efeito estufa no ano de 2020.	35
Tabela 3- Uso e ocupação do solo nas bacias hidrográficas em estudo.....	70
Tabela 4 – Classificação do solo das bacias hidrográficas em estudo.....	72
Tabela 5- Declividade da bacia potiribu conforme a classificação da EMBRAPA (1979).	73
Tabela 6 – Precipitação acumulada mensal (mm) e média anual (mm) entre os períodos históricos 1931-1960, 1961-1990 e 1991-2020 da Estação Climática de Cruz Alta do Instituto Nacional de Meteorologia – INMET...	76
Tabela 7 – Estações pluviométricas e dados de precipitação utilizados na pesquisa.	80
Tabela 8 – Estações fluviométricas e dados utilizados na pesquisa.	81
Tabela 9– Valores mínimos, máximos, médios e desvio padrão de vazão (Q), concentração de sedimentos em suspensão (CSS) e produção de sedimentos em suspensão (PSS) por bacias e total de registros de dados utilizados na pesquisa.	82
Tabela 10 – Separação de amostras para a execução dos modelos de RNAs.	84
Tabela 11 – Combinações das variáveis de entrada utilizada nos modelos de RNAs para estimar a PSS.	85
Tabela 12 – Dados de precipitação baixados da plataforma PROJETA INPE.....	90
Tabela 13 - Resultados das estatísticas dos Modelos de redes neurais artificiais para estimativa de PSS.	97
Tabela 14 – Médias mensais de produção de sedimentos em suspensão (PSS) e variação delta (%) para os cenários climáticos futuros RCP4.5 e RCP8.5 e período observado para a bacia do potiribu.	146

SUMÁRIO

1 INTRODUÇÃO	17
2 HIPÓTESES	22
3 OBJETIVO	22
4 REFERENCIAL TEÓRICO	23
4.1 EROÇÃO E PRODUÇÃO DE SEDIMENTOS	23
4.1.1 Tipos de erosão.....	23
4.1.2 Transporte de sedimentos.....	26
4.1.3 Fatores que influenciam	27
4.2 MUDANÇAS CLIMÁTICAS E A INTERFERÊNCIA NA PRODUÇÃO DE SEDIMENTOS	32
4.3 MODELOS E CENÁRIOS CLIMÁTICOS.....	41
4.4 CORREÇÃO DE VIÉS.....	48
4.5 MODELO DE REDE NEURAL ARTIFICIAL (RNA)	55
4.5.1 Aplicação de modelos de rede neural artificial (RNA) na área hidroambiental	60
4.6 FILTROS DE TRANSFORMAÇÃO DE DADOS DE ENTRADA.....	63
4.7 ESTATÍSTICAS DE DESEMPENHO PARA MODELOS HIDROAMBIENTAIS...65	
5 MATERIAIS E MÉTODOS	67
5.1 ETAPA 1 – MONITORAMENTO	68
5.1.1 Caracterização da área de estudo	68
5.1.2 Análise e descrição dos dados das estações fluviométricas e pluviométricas da bacia Potiribu.....	77
5.1.3 Organização e consistência dos dados selecionados na pesquisa.....	78
5.2 ETAPA 2 – CENÁRIO ATUAL.....	83
5.2.1 Modelos de RNAs para estimativa de PSS.....	83
5.2.1.1 Separação das amostras	83
5.2.1.2 Variáveis de entrada dos modelos.....	84
5.2.1.3 Desenvolvimento e treinamento dos modelos	87
5.2.2 Estatísticas de desempenho dos modelos de RNAs	88
5.3 ETAPA 3: CENÁRIOS FUTUROS.....	89
5.3.1 Modelo climático regional (MCR) e obtenção dos dados simulados.....	89

5.3.2 Correção de viés dos dados do modelo climático regional Eta-HadGEM2-ES CPTEC/INPE.....	90
5.3.3 Aplicação dos modelos para os cenários climáticos (observado e cenários futuros RCP 4.5 e RCP 8.5)	92
5.3.4 Análise do comportamento sazonal das séries temporais simuladas pelo modelo RNA nos cenários climáticos	92
6 RESULTADOS E DISCUSSÃO	95
6.1 ANÁLISE E ESCOLHA DO MELHOR MODELO DE PRODUÇÃO DE SEDIMENTOS EM SUSPENSÃO.....	95
6.2 RESULTADOS DA PSS PARA OS DIFERENTES CENÁRIOS CLIMÁTICOS SIMULADOS PELO MODELO ESCOLHIDO.....	108
6.3 ANÁLISE DO COMPORTAMENTO SAZONAL DAS SÉRIES TEMPORAIS SIMULADAS PELO MODELO RNA NOS CENÁRIOS CLIMÁTICOS	122
6.4 COMPARAÇÃO DAS PROJEÇÕES DOS CENÁRIOS FUTUROS COM O PERÍODO OBSERVADO.....	134
7 CONSIDERAÇÕES FINAIS	151
REFERÊNCIAS BIBLIOGRÁFICAS.....	153
APÊNDICE.....	168

1 INTRODUÇÃO

A produção de sedimentos em uma bacia hidrográfica é um fenômeno natural decorrente de ações de agentes erosivos como, água e vento e ainda da ação antrópica, podendo ocasionar erosões no solo (principalmente nas cabeceiras das bacias, caracterizadas por maior declividade), nas margens e no leito dos rios, sendo os sedimentos erodidos transportados até a calha do rio principal. Nos últimos anos, no entanto, os processos de erosão, de transporte e de deposição do solo vêm sendo intensificados, gerando alteração significativa na dinâmica hidrossedimentológica em escala global e local (MORGAN, 2005).

A maior quantidade de sedimentos em suspensão transportados pelos cursos d'água (cerca de 70 a 90%), ocorre em períodos de chuvas, principalmente durante as fortes precipitações (CARVALHO, 2008). Além disso fatores como declividade, rede de drenagem, vazão, uso e manejo do solo e tipo de solo de uma bacia hidrográfica, também influenciam o processo erosivo (MORGAN, 2005).

Esses fatores são extremamente importantes de serem avaliados, principalmente, em bacias rurais, como é o caso da área em estudo, a bacia do rio Potiribu, localizada na região noroeste do RS sobre o derrame basáltico sul-rio-grandense. É monitorada há mais de 30 anos pelo Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul (IPH/UFRGS), o qual está sofrendo com problemas de escoamento superficial, de erosão do solo, com presença de ravinhas e voçorocas (CASTRO; CHEVALLIER; SILVEIRA, 1993; CASTRO, 1996; CASTRO *et al.*, 1999; VIERO, 2004), devido às intensas atividades agrícolas.

No estado do Rio Grande do Sul (RS), por exemplo, é de conhecimento que a agricultura é uma atividade muito importante. Segundo a Fundação de Economia e Estatística – FEE (2015) o Estado ocupa posição estratégica para a oferta nacional de diversos produtos agrícolas como arroz, trigo, aveia e está entre os principais exportadores de fumo, soja e arroz. De fato, a agricultura está presente em praticamente todas as regiões do território gaúcho e pode-se destacar o município de Cruz Alta como o 4º maior exportador de soja, localizado na região noroeste do RS (DEPARTAMENTO DE POLÍTICAS AGRÍCOLAS E DESENVOLVIMENTO RURAL, 2020). Isso se deve aos solos profundos e bem drenados e ao clima que tem quatro estações do ano bem definidas, com chuvas regulares sendo ideal para a agricultura.

Nela são cultivadas a soja e milho no verão e trigo e aveia no inverno. Porém, o cultivo intensivo acelera a produção de sedimentos nas bacias.

Portanto, a produção de sedimentos em bacias agrícolas afeta vários atores como os proprietários de terras que perdem a camada superficial do solo, juntamente com nutrientes e insumos aplicados ao solo, as centrais hidrelétricas por ter os seus reservatórios assoreados e conseqüentemente diminuindo a vida útil dos mesmos e também pelo desgaste das turbinas devido aos sedimentos. Outros problemas associados aos sedimentos são a degradação das águas superficiais, que conseqüentemente encarece o tratamento de água para consumo humano, e prejudica a comunidade de pescadores e até o lazer.

As mudanças climáticas também podem se configurar em fator importante no processo erosivo, especialmente pela tendência futura de aumento das temperaturas e de mudanças nos padrões das precipitações, tanto em intensidade como na distribuição, o que poderá impactar na dinâmica hidrológica e sedimentológica de uma bacia hidrográfica. As mudanças climáticas poderão ainda, ter amplas implicações para os recursos hídricos em termos de quantidade e qualidade de água, de carreamento de sedimentos e nutrientes (WANG; HEJAZI, 2011), e pelo aumento no estresse da biodiversidade e da vegetação (IPCC, 2019, 2022), e ainda podendo impactar milhões de pessoas à insegurança alimentar e hídrica, especialmente na África, Ásia, América Central e do Sul, em Pequenas Ilhas e no Ártico conforme IPCC (2022).

Dessa forma entender a dinâmica da produção de sedimentos em uma bacia pode auxiliar no gerenciamento dos recursos hídricos e no manejo do solo. Para isso, entretanto, é importante investir no monitoramento contínuo e de longo período de bacias hidrográficas, de modo a possibilitar a obtenção de dados como, vazão, precipitação, nível d'água, turbidez, concentração de sedimentos em suspensão (CSS), que auxiliam na caracterização desses processos hidrossedimentológicos. Todavia, há que se considerar que, nem sempre é possível realizar este monitoramento contínuo por longos períodos, devido, principalmente, ao alto custo financeiro em manter os equipamentos, às saídas à campo para manutenção e para coleta dos dados e também, em razão de toda a logística necessária. Assim, associado ao monitoramento dessas bacias, modelos hidrossedimentológicos têm sido utilizados para estimar a carga de sedimentos, desde que se tenha um período

suficiente de dados para calibrar e verificar esses modelos com boa representatividade dos processos simulados.

Nesse cenário, a modelagem surge como uma ferramenta para auxiliar na estimativa da produção de sedimentos em suspensão (PSS) ou por arraste, empregando outras variáveis mais facilmente medidas como, por exemplo, a precipitação, a cota do rio, a vazão e a turbidez. Dessa forma, deve-se monitorar essas variáveis por um período suficiente para treinar e validar o modelo hidrossedimentológico, permitindo desse modo realizar previsões de descarga sólida em suspensão ou por arraste.

Os modelos climáticos globais e regionais, por sua vez, são importantes ferramentas para realizar projeções futuras de precipitações, auxiliando no fornecimento de informações sobre mudanças climáticas em diferentes cenários de emissão de gases de efeito estufa. Porém, os resultados de precipitação simulados pelos modelos climáticos globais (MCGs) e regionais (MCRs) podem apresentar grandes viés sistemáticos, em relação aos dados observados (SILLMANN *et al.*, 2013), assim, é necessária a utilização de métodos de correção de viés para a melhoria dos resultados que envolvem a temática hidrológica e de mudanças climáticas.

Muitas pesquisas que utilizam MCGs e MCRs avaliam as mudanças climáticas relacionadas às variáveis hidrológicas (precipitação, evapotranspiração, vazão) (BRÊDA *et al.*, 2019; CHOU *et al.*, 2014B, OLIVEIRA *et al.*, 2019; SANTOS *et al.*, 2021; DEREZYNSKI *et al.*, 2020; CARVALHO *et al.*, 2021; ZHANG *et al.*, 2019; MELLO *et al.* 2021) e sedimentológicas (CSS e PSS) (FAGUNDES, 2022; OLIVEIRA *et al.*, 2019; SANTOS *et al.*, 2021; CHUENCHUM; XU; TANG, 2020; ZHANG *et al.*, 2019) em escalas espaciais continentais, como América do Sul (BRÊDA *et al.*, 2019; FAGUNDES, 2022; CHOU *et al.*, 2014B), escala espacial de bacias hidrográficas abrangendo grandes áreas variando de 3.754 km² a 52.000 km² (OLIVEIRA *et al.*, 2019; CARVALHO *et al.*, 2021; ZHANG *et al.*, 2019; MELLO *et al.* 2021) e escala temporal diária (DEREZYNSKI *et al.*, 2020) e mensal (OLIVEIRA *et al.*, 2019; CARVALHO *et al.*, 2021; ZHANG *et al.*, 2019; MELLO *et al.* 2021).

Alguns autores têm demonstrado que os modelos de inteligência artificial (IA) podem ser eficazes nas previsões de variáveis hidroambientais, como é o caso da PSS (AFAN *et al.*, 2015; AFAN *et al.*, 2016; ADIB; MAHMOODI, 2017; BUYUKYILDIZ; KUMCU, 2017; PEKTAS; CIGIZOGLU, 2017; UCA *et al.*, 2018; CHOUBIN *et al.*, 2018;

YADAV *et al.*, 2022). Tais modelos são ferramentas muito úteis, que podem ser exploradas para o apoio nas tomadas de decisões em várias aplicações, como previsão agrícola, gerenciamento de ecossistemas, engenharia hidrológica e gerenciamento de recursos hídricos (SANIKHANI *et al.*, 2018). As redes neurais artificiais (RNA) destacam-se entre os modelos de inteligência artificial utilizados na área hidroambiental, e estão se tornando cada vez mais atrativas, especialmente devido às suas características de aprendizagem, pois são modelos conhecidos pela capacidade de lidar com problemas não lineares complexos como o processo chuva-vazão e também chuva-sedimentos (ASCE, 2000; MAIER; DANDY, 2000). As RNAs podem implementar relações mesmo com ruídos e erros de medição, sendo práticas e fáceis de usar após o treinamento (HSU; GUPTA; SOROOSHIAN 1995; ASCE, 2000). Além disso, as RNAs podem apresentar desempenho igual ou melhor em relação aos modelos conceituais ou físicos (ASCE 2000; BANIHABIB, 2016).

Nos últimos anos os modelos de Redes Neurais Artificiais (RNAs) vêm sendo aplicados para solucionar problemas na área hidroambiental, envolvendo desde estimativas de vazões (MATOS; PEDROLLO; CASTRO, 2014; OLIVEIRA; PEDROLLO; CASTRO, 2014; SHOAIB *et al.*, 2018), teor de umidade no solo (OLIVEIRA *et al.*, 2017; BARTELS *et al.*, 2021), preenchimento de falhas de séries temporais de chuva (DEPINÉ *et al.*, 2014), estimativa de concentração de sedimentos em suspensão (BAYRAM; KANKAL; ÖNSOY (2012), SARI; CASTRO; PEDROLLO (2017), CAMPOS (2019); TEIXEIRA *et al.* (2020) e estimativas de produção de sedimentos em suspensão (PSS) (LAFDANI; NIA; AHMADI, 2013; AFAN *et al.*, 2015; ADIB; MAHMOODI, 2017; BUYUKYILDIZ; KUMCU, 2017; PEKTAS; CIGIZOGLU, 2017; UCA *et al.*, 2018; CHOUBIN *et al.*, 2018; YADAV *et al.*, 2022), sendo que os resultados desses estudos têm demonstrado a viabilidade da utilização destes modelos nas mais diversas áreas.

Entretanto, modelos baseados em RNAs comumente necessitam de uma longa série de dados para treinamento, validação e verificação, além de sua aplicação ser restrita aos limites de domínio para os quais o modelo foi treinado. Isso, muitas vezes, inviabiliza o emprego desses modelos em regiões com redes de monitoramento deficientes, uma realidade quando se trata das redes sedimentológicas presentes em muitas das regiões do globo (SARI; CASTRO; PEDROLLO, 2017), sobretudo em países em desenvolvimento como o Brasil.

Embora alguns estudos tenham proposto novas técnicas de validação de modelos baseados em RNAs (SINGH; PANDA, 2011; SARI *et al.*, 2017), oferecendo alternativas ao problema da limitação de dados disponíveis, ainda existem, na maioria dos locais, dificuldades para obtenção de dados suficientes para treinamento, validação e verificação dessas redes, sobretudo no que se refere à variabilidade espacial desses dados. Portanto, buscou-se nesta pesquisa combinar dados de entrada provenientes de diferentes escalas de bacias hidrográficas agrícolas (Potiribu, Cambará, Taboão, Turcato, Alemão, Donato), localizadas na região noroeste do estado do Rio Grande do Sul, de uma mesma região hidrográfica, utilizando a área de cada bacia como seu identificador, para compor modelos RNAs regionais para a estimativa da PSS, procurando, dessa forma, contornar a insuficiência de dados disponíveis para representar a variabilidade espacial dos processos hidrossedimentológicos de uma dada região analisada.

Perante o cenário atual da região de estudo, pela influência agrícola na produção de grãos e as consequências devido a essa intensa atividade, almejou-se ampliar os conhecimentos e aproveitar os dados medidos há mais de 30 anos na região para analisar o quanto de solo essa região está perdendo.

Além disso, a preocupação com as mudanças climáticas tão discutida nos últimos anos, trouxe a esta pesquisa a oportunidade de verificar na mesma região de estudo se essa realidade pode também estar influenciando nesse processo. A presente pesquisa visa preencher lacunas importantes de conhecimento ao avaliar a variação da produção de sedimentos em suspensão em dois cenários de mudanças climáticas futuras em bacias agrícolas de diferentes escalas espaciais e em uma escala temporal de três horas. Visto que existem lacunas em relação a estudos envolvendo mudanças climáticas para regiões como o sul do Brasil e ainda escalas regionais como bacias hidrográficas de pequena escala (1 a 600 km²). Assim, sendo necessário maior detalhamento das informações relacionadas.

Portanto, procurou-se trazer informações capazes de auxiliar outras pesquisas e os setores envolvidos na adequação das práticas de uso e de manejo do solo, orientando na escolha de medidas mitigadoras dos problemas advindos da erosão do solo e da produção de sedimentos e também auxiliar, com os dados e as informações obtidas nesta pesquisa, no planejamento e gerenciamento de bacias.

2 HIPÓTESES

Foram formuladas as seguintes hipóteses para esta pesquisa:

1. Os modelos baseados em redes neurais artificiais podem ser aplicados para, a partir de cenários climáticos futuros, avaliar a produção futura de sedimentos em suspensão em bacias hidrográficas.
2. A integração de bacias hidrográficas de diferentes escalas pode constituir um recurso para a previsibilidade da PSS, com uma única RNA, nestas diferentes escalas, para compensar a escassez de dados por bacia.

3 OBJETIVO

Avaliar a variação da produção de sedimentos em suspensão em dois cenários de mudanças climáticas futuras, para bacias agrícolas de diferentes escalas, utilizando um modelo integrado em uma única RNA para a estimativa da produção de sedimentos em suspensão.

4 REFERENCIAL TEÓRICO

Neste capítulo são revisados os conceitos e os métodos relacionados à erosão do solo, à produção, ao transporte de sedimentos em suspensão e suas variações em relação às mudanças climáticas. Apresenta-se ainda, uma revisão acerca da modelagem hidrossedimentológica a partir dos modelos de redes neurais artificiais e também, sobre modelos climáticos, tendo como base literatura internacional e nacional.

4.1 EROSÃO E PRODUÇÃO DE SEDIMENTOS

4.1.1 Tipos de erosão

A erosão é o fenômeno do desgaste das rochas e do solo, que ocorre devido as ações dos agentes como, por exemplo, a água e o vento. Esse fenômeno é muito estudado na agricultura, pois é de grande importância para a conservação dos solos e também na engenharia para a proteção de obras civis como, estabilização de taludes, construção de estradas, regularização de cursos d'água, proteção de margens de rios e de reservatórios. Ambas as áreas de estudos devem obter um amplo conhecimento neste fenômeno para seu controle e mitigação (CARVALHO, 2008).

Os processos erosivos dependem de vários fatores e podem ocorrer de diferentes formas, entre elas erosão geológica, acelerada, hídrica e eólica. A erosão geológica, também chamada de erosão natural, caracteriza-se por um processo natural, de baixa intensidade, envolvendo o desprendimento das partículas ou materiais (solos, formações superficiais e pedras) e o seu deslocamento, sem interação humana, atuando gradativamente em todos os meios em escala de tempo geológica. Já a erosão acelerada, também chamada de erosão antrópica, é induzida pelas atividades humanas como agricultura, obras civis, mineração, entre outras, e caracteriza-se pela intensidade acelerada podendo tornar-se prejudicial ao meio ambiente (SILVA, 1995; CARVALHO, 2008; MÜLLER *et al.*, 2021). A erosão hídrica, por sua vez, é ocasionada pela ação da água no solo, sendo classificada em: I) erosão pluvial, que é produzida pelo impacto das gotas de chuva ao caírem sobre as superfícies desprotegidas (CARVALHO, 2008); II) erosão fluvial que ocorre nos

cursos d'água de modo contínuo e espontâneo pela ação das correntes dos rios (CARVALHO, 2008); III) lacustre, causada pela ação dos lagos; e IV) marinha, causada pela ação dos mares, que desgastam rochas e solos, levando à formação de falésias, além de ser responsável pela dissolução de minerais e rochas, em especial as calcárias (MÜLLER *et al.*, 2021; SILVA, 1995). A erosão eólica que é provocada pelo vento, ocorre quando a superfície está muito seca e as partículas do solo perdem sua coesão, sendo transportadas de um lugar e depositadas em outro (MÜLLER *et al.*, 2021; CARVALHO, 2008).

A erosão pluvial acontece em superfícies planas e inclinadas tendo mais força em terrenos com maior inclinação. Inicia-se o processo erosivo a partir da precipitação que ao entrar em contato com o solo desprotegido consegue desagregá-lo, e removê-lo para outro local, dependendo da sua intensidade ao chegar ao solo. Este contato com as gotas de água da chuva que caem no solo chama-se de efeito *splash* (Figura 1a e 1b), com a energia cinética da chuva associada ao diâmetro da gota d'água que impacta e desprende as partículas do solo, promovendo a compactação dos poros menores ao seu redor e dificultando o processo de infiltração. Após, inicia-se o processo de selamento da superfície do solo e a possível formação de poças (*puddle*) de água, que dariam início ao escoamento superficial – *runoff* (MORGAN, 1986; GUERRA, 2009; BRIZZI; SOUZA; COSTA, 2019), que corresponde a um filete de água que se desloca encosta abaixo podendo provocar simplesmente a lavagem da superfície do solo, dos terrenos arados, ou ainda, ocasionar a remoção de camadas delgadas do solo. Esse processo é designado escoamento laminar ou erosão laminar (PAIVA; PAIVA, 2016).

Esse selamento não está associado apenas à saturação do solo, podendo estar também ligado ao nível de compactação desse solo, assim como ao arranjo das partículas, à mudança abrupta da textura em perfil e ainda, ao índice de micro e macroporosidade do solo, os quais influenciam na infiltração da água da chuva na superfície (BRIZZI; SOUZA; COSTA, 2019).

Figura 1 – Efeito splash em uma superfície plana (a) e inclinada (b).



Fonte: SERGIEIEVA, 2021.

Quando as chuvas são mais intensas e os solos são favorecidos por parâmetros de natureza natural e antrópica, tais como, relevo íngreme, solos com menor agregação e desestruturados, uso e ocupação do solo inadequado, a erosão pode se desenvolver por escoamento concentrado ou linear, formando sulcos na superfície do terreno, podem evoluir para ravinas e atingir a configuração de voçorocas, as quais representam a forma mais grave de erosão em sulcos (CARVALHO, 2008; PAIVA; PAIVA, 2016). Na figura 2 é apresentada uma representação esquemática da formação de voçoroca.

Figura 2 – Formação detalhada de voçoroca.



Fonte: TEIXEIRA *et al.*, 2009.

As partículas de solos que foram desprendidas podem ser deslocadas pelo escoamento superficial até os locais mais planos onde acabam se depositando, ou ainda ser carreadas até as calhas dos rios. A quantidade de material erodido

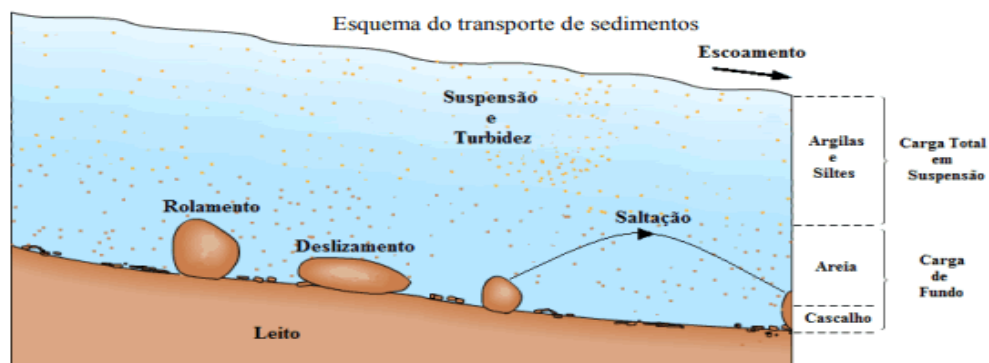
(partículas de solos) que conseguem completar o percurso, desde a sua origem até uma seção de um rio, ou reservatório, são comumente chamados de contribuição ou produção de sedimentos ou rendimento sólido (CARVALHO, 2008).

4.1.2 Transporte de sedimentos

O deslocamento e o transporte de sedimentos dependem da forma, do tamanho, do peso da partícula e das forças exercidas pela ação do escoamento. Os sedimentos que chegam ao curso d'água têm diversas granulometrias e sofrerão um processo de transporte variável conforme as condições locais e do escoamento. As cargas de sedimentos podem ser transportadas pelos rios de três maneiras diferentes (SUBCOMMITTEE ON SEDIMENTATION, 1963):

- **Carga Sólida de Arrasto:** são partículas de sedimentos que rolam ou deslizam longitudinalmente no curso d'água, encontrando-se em contato com o leito praticamente todo o tempo (Figura 3).
- **Carga Sólida Saltante:** são as partículas de sedimentos que saltam (pulam) ao longo do curso d'água por efeito da corrente ou devido ao impacto de outras partículas (Figura 3).
- **Carga Sólida em Suspensão:** são as partículas de granulometria pequena capazes de serem suportadas pelas componentes verticais das velocidades do fluxo turbulento, enquanto estão sendo transportadas pelas componentes horizontais dessas velocidades, com movimentos de subida e descida na corrente acima do leito (Figura 3).

Figura 3- Formas de deslocamento e transporte dos sedimentos nos cursos d'água.



Fonte: COUTO, 2019.

Cerca de 70 a 90% da produção de sedimentos que alcançam os rios, encontra-se em suspensão (partículas menores) e podem se depositar no leito (partículas maiores) (MORGAN, 2005), gerando alguns impactos na bacia hidrográfica como inundações, assoreamento de rios e reservatórios, degradação das águas superficiais, prejuízos ao desenvolvimento da fauna local, interferências nas estruturas hidráulicas (CARVALHO, 2008; CHOUBIN *et al.*, 2018), nos reservatórios, e na morfologia dos rios (CHEN *et al.*, 2018). Há que se considerar ainda que, os que chegam ao rio podem transportar consigo poluentes adsorvidos, como nutrientes químicos, inseticidas, herbicidas e metais pesados (NOVOTNY e OLEM, 1994). Além disso, os sedimentos em excesso nos rios prejudicam o turismo. Um exemplo disso, é o rio da Prata, de águas azuis e cristalinas, na região de Bonito (MS), muito utilizado para o ecoturismo, que está sofrendo com as altas concentrações de sedimentos. Após eventos de chuva com intensidade entre 25,1 a 50mm/h as águas cristalinas ficaram mais turvas e amarronzadas, em consequência da redução de vegetação decorrente do avanço da agricultura ao entorno (GAIGHER, 2019).

4.1.3 Fatores que influenciam

O aporte de sedimentos em uma bacia hidrográfica é influenciado por fatores que regulam os processos hidrossedimentológicos das áreas de vertentes até a calha do rio principal (SANTOS, 2013). Estes fatores são o clima, as características fisiográficas da bacia e o uso e manejo do solo (MORGAN, 2005), especialmente pela mudança da paisagem, por meio da retirada de florestas para utilização das terras para agricultura, pecuária e/ou construção de edificações.

O fator clima escala curta de tempo, através do regime de chuvas, sendo diretamente proporcional à intensidade e à frequência de ocorrência.


Os efeitos provocados no solo por uma chuva forte são bem diferentes dos efeitos de uma chuva com a mesma quantidade de água, porém com duração mais prolongada. As chuvas mais fracas e prolongadas contribuem para uma maior infiltração da água, alimentando o lençol subterrâneo. Por outro lado, em regiões tropicais, a intensidade das chuvas costuma ultrapassar 150mm/h. Estas precipitações torrenciais durante o período chuvoso com taxas de escoamento extremamente elevadas constituem uma forma mais agressiva de impacto da água no solo (PAIVA; PAIVA, 2016).

As características fisiográficas das bacias são fatores que influenciam na capacidade de transferência dos sedimentos até a calha do rio principal, sendo

representadas pela declividade, pelas características da rede de drenagem e pelo tipo de solo (MORGAN, 2005). Uma bacia com declividade alta, por exemplo, tem velocidade do escoamento superficial também alta, chegando esse escoamento rapidamente à calha do rio principal, o que ocasiona um aumento na vazão de pico, podendo resultar em erosão nas áreas de maior declividade e inundação na parte baixa da bacia. Já em bacias com menor declividade, há um achatamento da curva (do hidrograma), pois o escoamento chega mais lentamente ao exutório da bacia e esse escoamento mais lento também provoca menos erosão. Além da declividade, o tamanho das bacias também influencia no tempo que o escoamento levará para chegar a seção do rio principal. Em bacias de maior área, o tempo de resposta (entre o início do escoamento e a chegada dele na seção fluviométrica) será maior em comparação a bacias de menor área. Portanto, percebe-se que o aporte de sedimentos oscila dependendo da escala espacial considerada podendo ser regular ou intenso na bacia hidrográfica considerada (WARRICK *et al.*, 2013).

Na figura 4 são apresentados dois hidrogramas A e B. Nesse caso, “A” para o comportamento da resposta de chuvas intensas que tendem a gerar mais escoamento e hidrogramas mais pronunciados, com tempo de resposta mais rápido. Já em “B” observa-se um achatamento ou prolongamento do hidrograma, representando chuvas menos intensas e menor vazão de pico (COLLISCHONN; TASSI, 2008).

Figura 4 – Representação de dois hidrogramas A e B a partir de uma chuva efetiva.

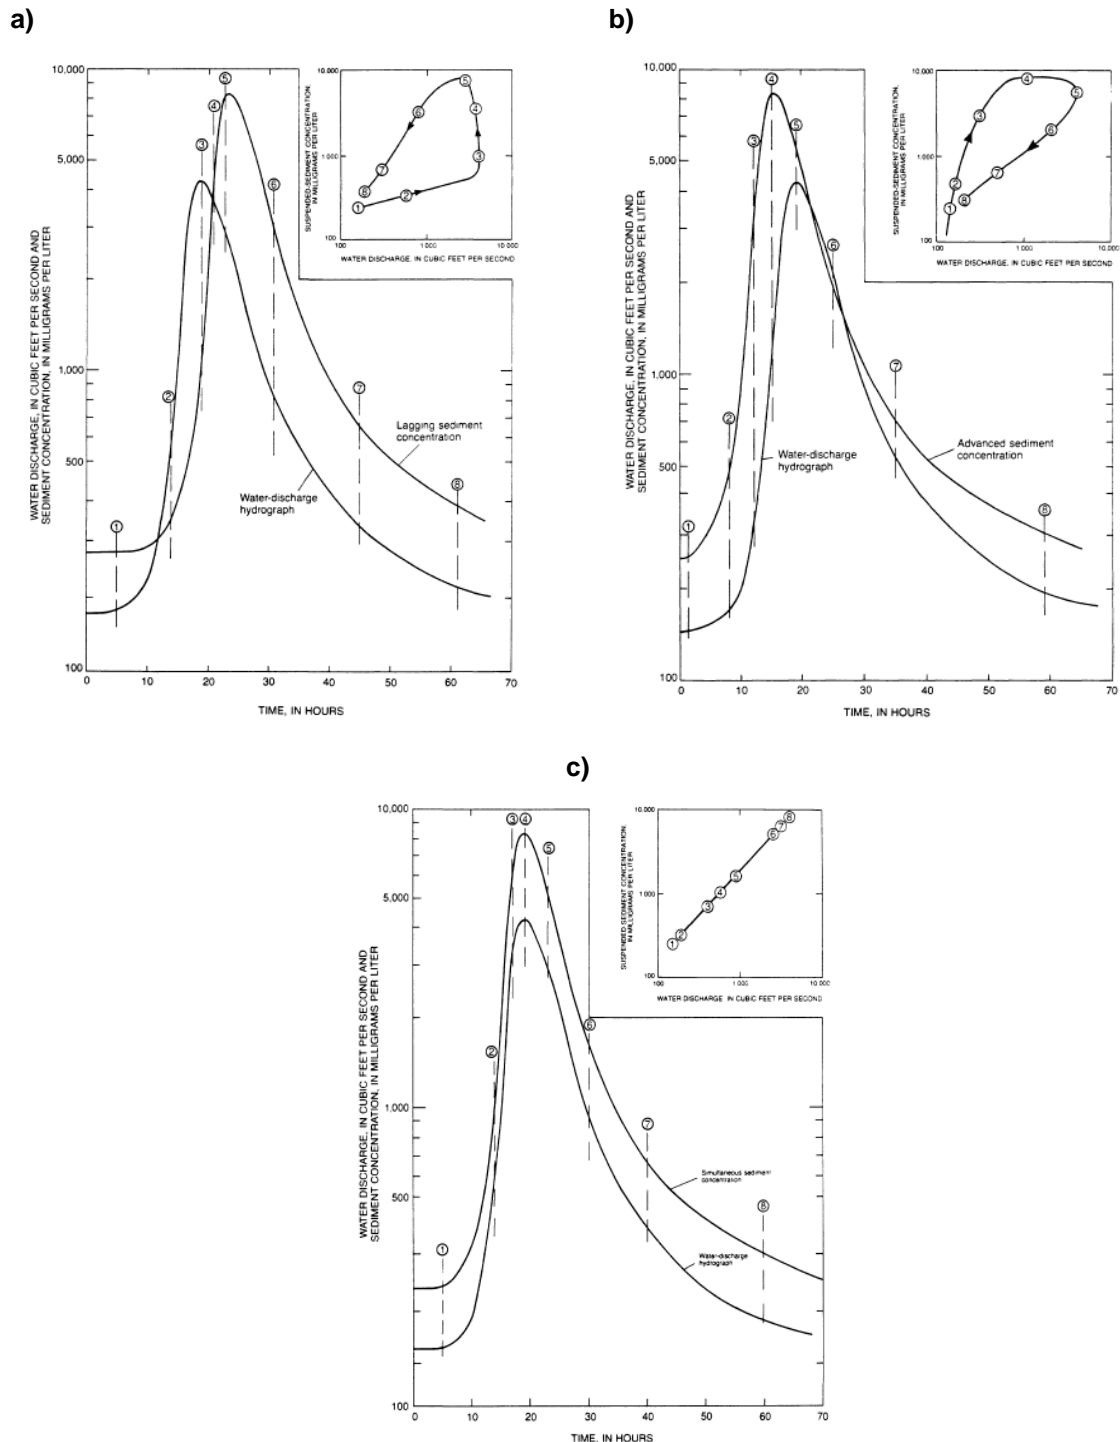


Fonte: Adaptado de COLLISCHONN; TASSI, 2008.

O comportamento do transporte dos sedimentos é representado através do sedimentogramas (Carga sólida x Tempo), a partir dos dados observados em uma seção transversal do rio. Geralmente, as curvas de sedimentos são dependentes das mudanças da descarga líquida, existindo vários fatores que podem afetar a forma, a inclinação e a interceptação da curva de transporte de sedimentos. Alguns dos mais importantes são: (1) estações do ano, (2) tempo entre o pico de concentração de sedimentos e o pico de descarga de água e (3) eventos extremos de cheias (GLYSSON, 1987).

Após um evento de chuva pode-se verificar a quantidade de sedimentos transportada, a qual forma uma onda que acompanha a onda de enchente de três formas diferentes: na primeira, o pico da carga sólida se atrasa em relação à vazão (Figura 5a); na segunda, onde o pico da carga sólida e líquida se igualam no movimento (Figura 5b); e na terceira, na qual o pico da carga sólida se antecipa ao da vazão (Figura 5c) (GLYSSON, 1987). A situação mais comum é aquela em que o pico de sedimentos se antecipa ao pico da enchente (GLYSSON, 1987). Esse comportamento é chamado de efeito histerese, pois o fluxo de sedimentos em um curso d'água é tão complexo que as funções matemáticas ainda não permitiram uma definição completa (CARVALHO, 2008).

Figura 5- Formas diferentes do comportamento da onda de sedimentos em relação a vazão: a) Pico de carga sólida se atrasando em relação ao pico da vazão; b) Pico de descarga e de carga sólida acontecendo simultaneamente; c) Pico de carga sólida se antecipa ao pico de vazão.



Fonte: GLYSSON, 1987.

Além do escoamento superficial, o escoamento subsuperficial e o de base contribuem para a geração do hidrograma (BARROS *et al.*, 2021). Barros *et al.* (2021)

avaliaram diferentes fontes de escoamento nos hidrografa de uma pequena bacia rural localizada em Arvorezinha Rio Grande do Sul, concluindo que há uma contribuição média de 62% de escoamento subsuperficial e de base para a vazão durante os eventos de chuva na bacia. Essa contribuição desses fluxos de menor velocidade, que o do escoamento superficial, tem impacto direto na simulação hidrológica e sedimentológica (BARROS *et al.*, 2021).

Além disso, foi mencionado anteriormente que a alteração da paisagem é um fator importante na produção de sedimentos. Portanto, para bacias rurais é importante avaliar o manejo do uso do solo, o tipo de solo e os tipos de culturas que são empregadas na região de estudo.

No estado do Rio Grande do Sul, por exemplo, é de conhecimento que a agricultura é uma atividade muito importante. Segundo a Fundação de Economia e Estatística – FEE (2015) o Estado ocupa posição estratégica para a oferta nacional de diversos produtos agrícolas como arroz, trigo, aveia e está entre os principais exportadores de fumo, soja e arroz. De fato, a agricultura está presente em praticamente todas as regiões do território gaúcho e pode-se destacar o município de Cruz Alta como o 4º maior exportador de soja (DEPARTAMENTO DE POLÍTICAS AGRÍCOLAS E DESENVOLVIMENTO RURAL, 2020).

O manejo utilizado nas lavouras na maioria do estado, principalmente sob a região do planalto e sobre latossolos, é conduzido sob plantio direto (SECCO *et al.*, 1997). O Sistema de Plantio Direto (SPD) consiste na semeadura das culturas sobre a palha das culturas anteriores com o mínimo de perturbação do solo (DERPSCH *et al.*, 2011; HERNANI *et al.*, 2002). Esse sistema preconiza três princípios básicos como: baixo revolvimento do solo, a presença de cobertura viva ou morta sobre o solo (palhada), e a rotação de culturas. Os sistemas que apresentem sucessão de culturas, como soja na safra e milho na safrinha, ou trigo ou outra cultura, no entanto, não caracterizam um sistema plantio direto essencialmente (PASSOS; ALVARENGA; SANTOS, 2018).

Algumas pesquisas no Sul do Brasil apontam que existem problemas ambientais significativos associados ao escoamento superficial e à produção de sedimentos sob o sistema de plantio direto (DIDONE; MINELLA; MERTEN, 2015). Deuschle *et al.* (2019) investigaram em quatro macroparcelas experimentais no Sul do Brasil, com diferente manejo de solo, a erosão e a resposta hidrológica da escarificação e da intensificação da rotação de culturas em um SPD tradicionalmente

manejado sem rotação de culturas em uma encosta agrícola no sul do Brasil. Os autores constataram que nas macroparcelas com SPD com sequência de soja/trigo e 3 meses de pousio (SPD sem rotação de culturas) obteve-se a maior perda de água e solo com 182mm e 664 kg/ha, respectivamente, mostrando a fragilidade deste sistema como estratégia de conservação do solo e da água, mesmo em eventos de baixa intensidade. As perdas totais de água e de sedimento nas outras três macroparcelas (2: escarificação em SPD sem rotação de culturas; 3: SPD com rotação de cultura com soja/aveia + ervilhaca/milho/rabanete/trigo/soja/aveia + ervilhaca/milho e 4: escarificação em SPD com rotação de culturas) foram 159, 140 e 141mm e 384, 108 e 259 kg/ha, respectivamente. O estudo demonstrou, portanto, que a escarificação aumenta as perdas de solo durante eventos de alta intensidade, o que poderia ser uma consequência da perturbação do solo.

Desse modo, para uma melhor compreensão da produção de sedimentos em uma bacia hidrográfica, são realizados estudos hidrossedimentológicos, que buscam analisar a resposta dos efeitos desses fatores, de forma conjunta. Para isso é realizado o monitoramento de bacias hidrográficas, que consiste na obtenção de uma série temporal de dados de precipitação, de vazão, de nível de água, e de concentração de sedimentos em suspensão em estações fluviométricas instaladas em locais estratégicos. Esses dados possibilitam o cálculo do fluxo de sedimentos, que é caracterizado pela descarga sólida em suspensão (massa por unidade de tempo) e também, da produção de sedimentos, que é a integração do fluxo no tempo (MERTEN *et al.*, 2011). Associado a esses dados são utilizados modelos hidrossedimentológicos para estimar a carga de sedimentos quando se tem déficit de dados na área em estudo, ou ainda, para análises de práticas de gestão e de manejo, bem como para investigações de cenários futuros de interesse.

4.2 MUDANÇAS CLIMÁTICAS E A INTERFERÊNCIA NA PRODUÇÃO DE SEDIMENTOS

As mudanças climáticas e seus efeitos em escala global já são realidades comprovadas e muito discutidas nas comunidades científica e política. Já existem evidências que comprovam o aumento da temperatura média do ar e dos oceanos, o derretimento dos glaciais, e o aumento do nível médio dos mares (IPCC, 2022). Isso

se deve ao aumento das concentrações dos gases do efeito estufa (GEE), na composição do efeito estufa natural atmosférico.

Estes gases do efeito estufa são emitidos pela própria natureza e se encontram em uma concentração determinada na atmosfera para manter este equilíbrio. Cada um dos gases do efeito estufa tem uma influência importante na temperatura média da Terra (Tabela 1), sendo o vapor d'água o que exerce a maior influência, contribuindo com 20°C dos 33°C acrescentados à temperatura da superfície da Terra por conta do efeito estufa natural da atmosfera. O dióxido de carbono existente contribui com 7°C, entretanto, sua concentração atmosférica aumentou de 36% em 2012 para 149% em 2020. O mesmo acontece com o óxido nitroso e o metano que contribuem para o aumento da temperatura de 1,4°C e 0,8°C, respectivamente, estando suas concentrações na atmosfera aumentando de 18% para 123% e de 150% para 262% de 2012 para 2020, respectivamente (NOBRE; REID; VEIGA, 2012).

Tabela 1 - Influência relativa dos gases de efeito estufa no efeito estufa natural da atmosfera da Terra (coluna do meio) e crescimento das concentrações atmosféricas devido às emissões antropogênicas para CO₂, CH₄ e N₂O nos anos de 2012 e 2020.

GASES DO EFEITO ESTUFA	ΔT^*	CRESCIMENTO 2012*	CRESCIMENTO 2020**
Vapor d'água	20°C	–	
Dióxido de carbono (CO ₂)	7°C	36%	149%
Ozônio	2 a 3°C	–	
Óxido Nitroso (N ₂ O, Derivados)	1,4°C	18%	123%
Metano (CH ₄)	0,8°C	150%	262%
Demais gases	0,6°C	–	

Fonte: *Adaptação de NOBRE, REID e VEIGA, 2012; ** WMO, 2021.

Esse crescimento acelerado das concentrações dos GEEs no ar atmosférico é decorrente das intensas atividades antrópicas na Terra, desde o período da revolução industrial até os dias atuais, evidenciando o processo de aquecimento global.

Em 1988, a Organização Mundial das Nações Unidas para o Meio Ambiente (*United Nations Environment Programme* – Unep) e a Organização Meteorológica Mundial (OMM) criaram o Painel Intergovernamental sobre Mudança do Clima

(*Intergovernmental Panel on Climate Change – IPCC*), que consiste em realizar avaliações sobre as mudanças climáticas e seus impactos potenciais.

Segundo o Quinto relatório de avaliação (AR5) do IPCC (2014), o aumento das emissões globais dos gases do efeito estufa tiveram início em 1750, e até meados de 2011 já aumentaram em 40% nas concentrações de dióxido de carbono (CO₂), 150% de metano (CH₄) e 20% de óxido nitroso (N₂O), sendo o período de maiores emissões já registradas entre 2000 e 2010. No sexto relatório de avaliação (AR6) do IPCC (2021) é mostrada a contribuição para o forçamento radiativo de CO₂, CH₄, N₂O e as espécies halogenadas desde os anos 1900 até as décadas mais recentes. Para o período 1960-2019, a contribuição relativa para o forçamento radiativo efetivo total (ERF) foi de 63% para CO₂, 11% para CH₄, 6% para N₂O e 17% para as espécies halogenadas. O declínio sistemático na contribuição relativa para ERF para CH₄ desde 1850 é causado por uma taxa de aumento mais lenta de CH₄ nas últimas décadas, em 6, 10 e 5 ppb/ano durante 1850–2019, 1960–2019 e 2000–2019, respectivamente, em comparação com a taxa crescente de CO₂ (a 0,7, 1,6 e 2,2 ppm/ano, respectivamente) e N₂O (a 0,4, 0,7 e 0,9 ppm/ano, respectivamente). Devido ao menor tempo de vida do CH₄, o efeito de uma redução na taxa de aumento das emissões no aumento do ERF é evidente em escalas de tempo interdecadais (CANADELL *et al.*, 2021).

No boletim mais atual, publicado em outubro de 2021, da Organização Mundial de Meteorologia (*World Meteorological Organization – WMO*) sobre as emissões de gases do efeito estufa baseado nas medições globais do ano de 2020, sendo os principais GEEs antropogênicos CO₂, CH₄ e N₂O, que resultaram em uma concentração global média de 413,2±0,2 ppm, 1889±2 ppb e 333,2±0,1 ppb, respectivamente, atingindo 149%, 262% e 123% do nível pré-industrial que era de 278 ppm para CO₂, 722 ppb para CH₄ e 270 ppb para N₂O (Tabela 2).

Tabela 2 – Média anual global das emissões dos principais gases do efeito estufa no ano de 2020.

	CO₂	CH₄	N₂O
Abundância média global em 2020	413,2±0,2 ppm	1889±2 ppb	333,2±0,1 ppb
Abundância relativa de 2020 para o ano de 1750*	149%	262%	123%
Aumento absoluto (2019 - 2020)	2,5 ppm	11 ppb	1,2 ppb
Aumento relativo (2019 - 2020)	0,61%	0,59%	0,36%
Aumento absoluto anual médio nos últimos 10 anos	2,40 ppm/ano	8,0 ppb/ano	0,99 ppb/ano

* Assumindo uma fração molar pré-industrial de 278 ppm para CO₂, 722 ppb para CH₄ e 270 ppb para N₂O.

Fonte: WMO, 2021.

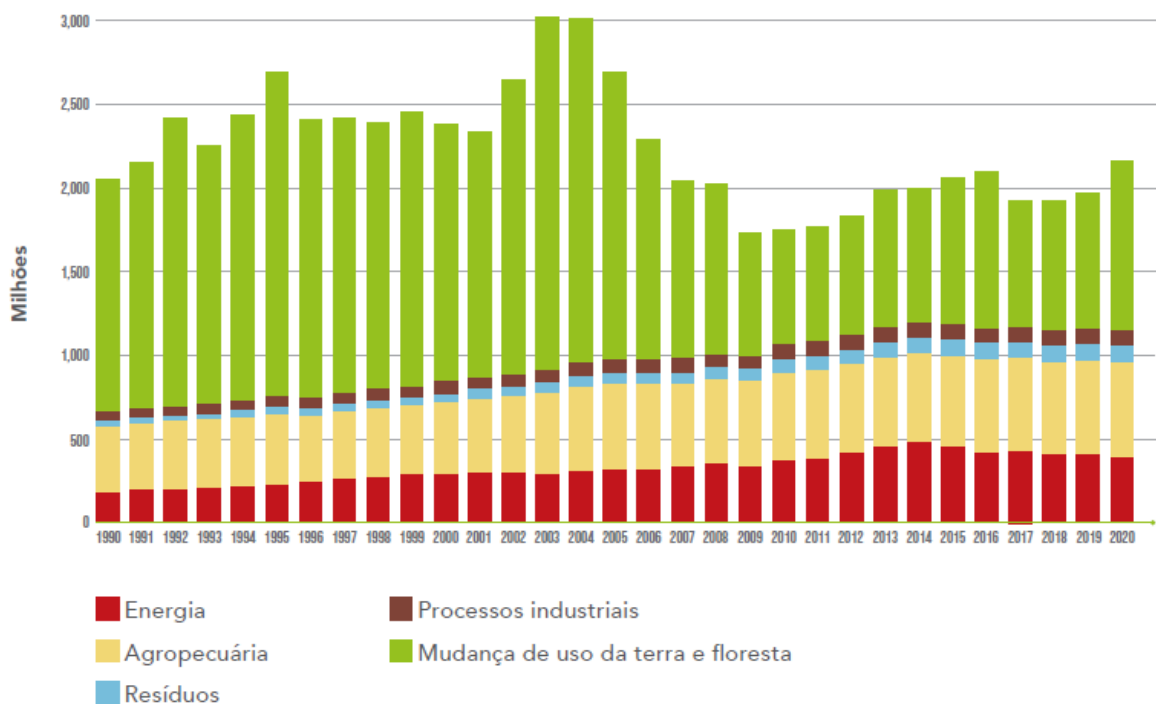
O Brasil, como país Parte da Convenção sobre Mudança do Clima, assumiu, com base em seu artigo 4º, parágrafo 1º, o compromisso de “elaborar, atualizar periodicamente, publicar e pôr à disposição da Conferência das Partes, em conformidade com o artigo 12, inventários nacionais de emissões antrópicas por fontes e remoções por sumidouros de todos os gases de efeito estufa não controlados pelo Protocolo de Montreal, empregando metodologias comparáveis a serem acordadas pelas Conferências das Partes”. Assim, o SEEG, Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa é uma iniciativa do Observatório do Clima que compreende a produção de estimativas anuais das emissões de gases de efeito estufa (GEE) no Brasil. O SEEG produz documentos analíticos sobre a evolução das emissões e disponibiliza em um portal na internet de forma simples e clara os métodos e dados do sistema. Estas estimativas realizadas pelo SEEG são geradas segundo as diretrizes do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), com base na metodologia dos Inventários Brasileiros de Emissões e Remoções Antrópicas de Gases do Efeito Estufa, elaborado pelo Ministério da Ciência, Tecnologia e Inovação (MCTI), e em dados obtidos junto a relatórios governamentais, institutos, centros de pesquisa, entidades setoriais e organizações não governamentais.

Em 2021 o SEEG publicou uma análise das emissões brasileiras de GEEs nos anos de 1970 a 2020, trazendo informações de emissões dos gases como CO₂, N₂O, CH₄ por setores, estados e municípios brasileiros. Neste relatório é ressaltado que as

emissões de GEEs brutas no Brasil foram de 2,16 bilhões de toneladas de CO₂ equivalente (GtCO_{2e}) no ano de 2020, constatando um aumento de 9,5%. Observou-se também que no ano em que a pandemia da Covid-19 parou a economia mundial, houve uma inédita redução de quase 7% nas emissões globais. Entretanto, o Brasil foi considerado o grande emissor do planeta e foi constatado alta nas concentrações de gases do efeito estufa de 2019 para 2020 (SEEG, 2021).


Em 2020, entre as atividades que mais emitiram este composto para a atmosfera no Brasil está o setor de mudança de uso da terra e florestas com 46%, sendo 998 milhões de toneladas de CO₂ equivalente (MtCO_{2e}), seguido da agropecuária com 27%, e do setor de energia com 18%, estando os setores de indústrias e resíduos com 5% e 4%, respectivamente (Figura 6 e 7). Essas emissões causadas pelas mudanças do uso da Terra se devem, principalmente, ao desmatamento do bioma Amazônia, que concentra 78,4% (782 MtCO_{2e}) das emissões brutas do setor em 2020 (SEEG, 2021).

Figura 6 – Emissões de gases de efeito estufa do Brasil de 1990 a 2020 (GtCO_{2e}).



Fonte: SEEG, 2021.

Figura 7 – Estimativas de emissões de CO₂ e GWP por setor no Brasil em 2020*.

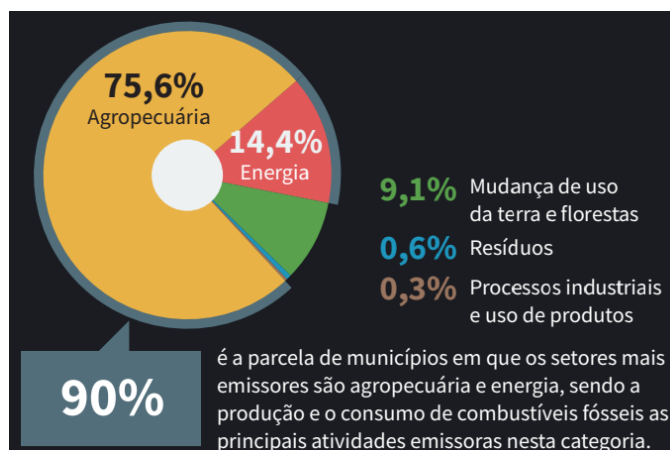


*Fatores de conversão de CO₂ e GWP de acordo com o 5º relatório do IPCC (IPCC AR5).
Fonte: SEEG, 2021.

Em relação às emissões estaduais, os três Estados que mais emitiram GEEs em 2020 por mudança de uso da terra foram Pará (354,2 Mt CO₂e), Mato Grosso (140,5 Mt CO₂e) e Amazonas (109,1 Mt CO₂e). Esses estados sozinhos representam 60,5% da emissão do setor (SEEG, 2021).

Na região Sul do Brasil que compreende os Estados do Paraná, Santa Catarina e Rio Grande do Sul, segundo o relatório do SEEG (2021), em 90% dos municípios, os setores que mais emitem GEEs são a agropecuária e a energia (Figura 8).

Figura 8 – Porcentagem dos municípios da região Sul do Brasil onde o setor é mais emissor.



Fonte: SEEG, 2021.

Essas emissões, como mencionado anteriormente, contribuem para o aumento significativo na temperatura do ar da superfície da terra, que desde o período pré-industrial (1850-1900) até os dias atuais (1999-2018) aumentou 1,44°C (IPCC, 2018). A causa mais provável para essa elevação é o conjunto das atividades antrópicas, como queima de combustíveis fósseis (nos automóveis, nas indústrias, usinas termoelétricas), queimadas, desmatamento, agropecuária, tratamento de resíduos etc.

O recente relatório publicado pelo IPCC (AR6), em agosto de 2021, mostra que no período de 2011 a 2020, comparado com o período pré-industrial (1850-1900), a temperatura do ar da superfície da terra já superou o que foi constatado no IPCC 2018; resultando um aumento de 1,59°C, em uma indicação direta de relação com as atividades humanas (IPCC, 2021). Outras conclusões recentes foram que a Terra está aquecendo mais rápido do que era previsto e que em 2030 já se prepara para atingir 1,5°C acima do período pré-industrial (1850-1900) sendo dez anos antes do que o esperado nas projeções. Tal cenário demonstra que haverá eventos climáticos extremos em maior frequência, como enchentes, secas e ondas de calor (IPCC, 2021).

Com as temperaturas mais quentes e as mudanças nos padrões das precipitações, tanto em intensidade como na distribuição, há um impacto na dinâmica hidrológica e sedimentológica das bacias hidrográficas, o que resulta em amplas implicações para os recursos hídricos em termos de quantidade e de qualidade de água, bem como em termos de carreamento de sedimentos e nutrientes (WANG; HEJAZI, 2011). Além disso, as mudanças climáticas causam também modificações no início e no fim das estações de cultivo, contribuindo para a redução regional da produção agrícola, e para a redução na disponibilidade de água doce, caso seja necessário maior uso de irrigação devido a essas alterações, além do aumento no estresse da biodiversidade e da vegetação (IPCC, 2019). Portanto, as mudanças climáticas podem induzir mudanças sazonais no escoamento e na concentração de sedimentos (HOVENGA *et al.*, 2016).

Vários autores mencionam em suas pesquisas as alterações do regime de chuvas e alterações nas descargas líquidas e disponibilidade hídrica (CHOU *et al.*, 2014b; BERLATO; CORDEIRO, 2017; BRÊDA *et al.*, 2021). Chou *et al.* (2014b) que avaliaram as mudanças climáticas na América do Sul reproduzidas por simulações de *downscaling* (redução de escala) utilizando o modelo regional Eta com as condições de contorno de dois modelos globais o HadGEM2-ES e o MIROC5. Os autores

observaram que eventos de chuvas intensas se tornam mais frequentes na área do sudeste da América do Sul à medida que os intervalos de tempo avançam no final do século XXI.

Brêda *et al.* (2021) analisaram projeções de mudanças climáticas médias nas bacias hidrográficas na América do Sul, utilizando um conjunto de 25 modelos globais como dados de entrada para o modelo hidrológico MGB-AS, buscando avaliar variáveis como evaporação média, precipitação média e vazão média. O estudo mostrou única região da América do Sul com tendência significativa no aumento da vazão e maior umidade é no Sudeste, que compreende a região Sul do Brasil, principalmente a bacia do rio Uruguai.

Berlato e Cordeiro (2017) destacam pesquisas publicadas sobre as tendências climáticas observadas no Rio Grande do Sul (RS) para o século XXI, as quais utilizaram regressão linear com ajuste pelo método clássico dos mínimos quadrados (WILKS, 1995), sendo a tendência foi avaliada pelo teste de hipótese (teste t). De modo geral, foi constatado aumento da temperatura média do ar, atribuído à forte elevação da temperatura mínima do ar. Ainda segundo Cordeiro *et al.* (2016) a temperatura média demonstrou tendência semelhante à temperatura mínima, com aumento no ano e nas quatro estações do ano; porém, com taxas de aumento bem menores que as da temperatura mínima e maiores que as da temperatura máxima. A tendência linear, no período 1950-2009, resultou em um aumento médio de 0,6 °C no ano; 0,8 °C na primavera, ambos estatisticamente significativos a 1%; de 0,8 °C no outono, significativo a 5%; e 0,3 °C no verão, a 10% de significância.

Em relação à precipitação anual do estado do Rio Grande do Sul Berlato e Cordeiro (2017) relatam que no período de 30 anos (1980-2009) houve aumento de 10% da precipitação pluvial anual em relação à normal climatológica de 1950-1979, com predominância para a primavera e o outono. Já na região noroeste do Rio Grande do Sul a nebulosidade e precipitação pluvial e, em especial, a umidade do ar, apresentaram tendência significativa de aumento na primavera e no verão (BERLATO; CORDEIRO, 2017).

Zhang *et al.* (2019) avaliaram os impactos potenciais do clima na mudança no escoamento e na produção de sedimentos em bacias hidrográficas de Zhenjianguan, localizada na região nordeste do planalto Tibetano - China (área = 4500 km²), utilizando um modelo de regressão entre fatores climáticos e fatores de cobertura vegetal e um modelo hidrológico distribuído (*Soil and Water Assessment Tool* - SWAT)

com base física. Os autores constataram que a precipitação é o fator mais sensível que afeta o escoamento e a produção de sedimentos na bacia, e uma mudança anual de 10% na precipitação pode causar uma alteração de 10% a 14% no escoamento anual e uma alteração de 17% a 24% na produção anual de sedimentos sendo cada aumento de 0,7°C na temperatura resultando em reduções de 1,4% à 2% no escoamento anual e de 2% à 3,7% na produção anual de sedimentos.

Uma parcela dos pesquisadores associa as alterações do uso e cobertura do solo com as mudanças climáticas que estão afetando, sobretudo, os regimes de chuva; especialmente como consequência da redução das áreas de vegetação para a substituição de áreas urbanas e agrícolas. Isso faz com que as bacias hidrográficas tenham uma alteração na produção de sedimentos e na vazão. De fato, este conjunto de fatores associados tende a aumentar essa produção de sedimentos. Pesquisas realizadas por Chuenchum; Xu; Tang (2020) que procuraram investigar as tendências da mudança de erosão do solo e produção de sedimentos a partir dos efeitos do clima e mudanças no uso da terra na Bacia do Rio Lancange Mekong na China usando o modelo RUSLE modificado. Os resultados mostraram que, em cenários futuros (2030 a 2040) a maioria das áreas florestais serão transformadas em áreas agrícolas e áreas urbanas devido às pressões do desenvolvimento socioeconômico nesta região, o que ocasionará, por consequência, um aumento da erosão do solo e da produção de sedimentos na maioria das áreas da bacia do rio Mekong. Os autores constataram também, que o fator mudança climática aumentou a precipitação média de toda a bacia, bem como o pico de precipitação em alguns pontos.

As mudanças no clima para o cenário brasileiro, segundo o pesquisador Artaxo (2021), podem impactar também a região central do país, onde a temperatura pode subir até 5,5 °C, e as chuvas podem cair 30% até o fim do século XXI. Essa é uma região onde atualmente são produzidas soja e carne, sendo provável a inviabilidade de produzir competitivamente daqui a 10, 20 ou 30 anos.

Zilli *et al.* (2020) buscaram quantificar os impactos econômicos, em termos de mudanças de área e de produção, das principais commodities brasileiras considerando a competição pelo uso da terra e os aspectos econômicos integrados ao GLOBIOM-Brasil. Os autores relatam que as duas principais culturas do Brasil, soja e milho, sofrerão uma realocação da produção para regiões subtropicais ou quase subtropicais dos biomas Cerrado e Mata Atlântica. Além disso, haverá uma redução

para ambas as culturas variando entre -6,3% e -36,5% para a soja e entre -12,9% e -29,4% para o milho, para o cenário projetado para 2050.

Santos *et al.* (2021) avaliaram os impactos futuros das mudanças no uso e cobertura do solo (LULC) e os impactos das mudanças climáticas no escoamento e na produção de sedimentos na bacia do rio Tapacurá (470 km²) no nordeste do Brasil, utilizando dados climáticos projetados derivados do MCG HadGEM2-ES acoplados ao modelo de MCR ETA-CPTEC/HadCM3 para dois cenários futuros (RCP 4.5 e 8.5). Os autores avaliaram os dois cenários futuros de LULC, otimista (atual LULC) e pessimista (as tendências de mudança de uso da terra continuam), usando o algoritmo perceptron multicamadas (MP). E para estimar o fluxo e a erosão futuros para diferentes períodos (2011–2040, 2041–2070 e 2071–2099) foi utilizado modelo SWAT. Na pesquisa relataram que as mudanças de LULC projetadas para 2050 foram de reduções nas classes pecuária e floresta tropical e sua substituição pelas classes agricultura e cana-de-açúcar observado em quase toda a bacia. E quanto aos processos de escoamento e produção de sedimentos foram mais intensos nas sub-bacias que possuem cobertura predominante de cana-de-açúcar em terreno ondulado. E concluíram que o reservatório presente na bacia terá um aumento considerável na disponibilidade hídrica e um aumento associado na produção de sedimentos que significa também um aumento considerável no risco de assoreamento diminuindo a vida útil do mesmo. E destacam que nas últimas décadas a bacia teve mudanças consideráveis na LULC devido ao aumento da pecuária e da agricultura e já alteraram a vazão e a produção de sedimentos em escalas de tempo sazonal e de longo prazo.

4.3 MODELOS E CENÁRIOS CLIMÁTICOS

As mudanças climáticas são avaliadas e estudadas através de projeções para o futuro, e para obter estas projeções os modelos climáticos geram simulações através das suposições descritas nos cenários de emissões de gases do efeito estufa (GEE), de poluentes atmosféricos e de padrões de uso da terra (IPCC, 2014).

Os cenários são gerados considerando os fatores que impulsionam as mudanças nas emissões antropogênicas de GEE, sendo eles: o crescimento econômico e populacional, o estilo de vida e as mudanças comportamentais, as mudanças associadas no uso de energia e no uso da terra, a tecnologia e a política

climática, que são fundamentalmente incertas. Este conjunto padrão de cenários usado no Quinto relatório de avaliação (AR5) é chamado de “*Representative Concentration Pathways (RCPs)*”, e corresponde a quatro forçantes radiativas, variando de 2,6 w/m², 4,5 w/m², 6,0 w/m² e 8,5 w/m², equivalentes à diferentes caminhos de concentração dos gases de efeito estufa para o final do século XXI, sendo que exatamente esse valor foram definidos 407,8 ppm para CO₂, 1.869 ppb para CH₄ e 331,1 ppb para N₂O (WMO, 2019), um cenário de mitigação rigoroso (RCP2.6), dois cenários intermediários (RCP4.5 e RCP6.0) e um cenário com emissões muito altas de GEE (RCP8.5) (IPCC, 2014).

O cenário de mitigação mais rigoroso, é o que pode ser chamado de mais otimista. O RCP2.6, prevê um pico na concentração de CO₂ de aproximadamente 460ppm e um declínio deste valor até o final do século XXI, sendo que atualmente esse valor é 413,2 ppm para CO₂, 1.889 ppb para CH₄ e 333,2 ppb para N₂O (WMO, 2020). O RCP4.5 e RCP6.0, estimam que a concentração de CO₂ atinja um pico de aproximadamente 650 ppm e 850 ppm, com estabilização e conseqüente redução das emissões na segunda metade e nas últimas décadas do século XXI, respectivamente. Já o cenário RCP8.5, é o considerado o mais pessimista, prevendo o aumento das emissões de GEE até atingir um pico de concentração de CO₂ de 1.370 ppm até o final do século XXI (IPCC, 2014).

Dentro desses cenários, é importante quantificar a alteração que as mudanças climáticas ocasionarão nos rios tanto nas descargas líquidas quanto nas sólidas. Para isso, é necessário em primeiro lugar prever quais são as chuvas que ocorrerão em cenários futuros devido às alterações climáticas e, após isso, com essas chuvas futuras, prever as vazões e a descarga sólida dos rios nos cenários futuros considerados.

Os modelos climáticos são representações matemáticas de processos importantes no sistema climático da Terra, variando desde modelos idealizados simples, modelos de complexidade intermediária até modelos gerais de circulação (MGCs) abrangentes, incluindo modelos do sistema terrestre (MSTs) que também simulam o ciclo do carbono (IPCC, 2014). Desde o AR4, publicado em 2007, até o AR5, publicado no ano de 2014, os modelos vêm sendo melhorados, aumentando a sua complexidade física nas simulações. Os modelos do AR5 já demonstram uma melhora, principalmente no que se refere aos dados de chuva, alcançando uma correlação 0,82 para o padrão espacial em relação aos dados de chuvas históricos

(1850 a 2005) ao período simulado no futuro (2006 a 2100) dos modelos do AR4 (FLATO, GREGORY; MAROTZKE, 2013).

Os modelos climáticos globais (MCGs) são ferramentas capazes de fornecer informações sobre mudanças climáticas em diferentes cenários de emissão de gases de efeito estufa. Para representar a variabilidade climática, esses modelos globais exigem que o oceano, a atmosfera e a superfície terrestre sejam acopladas. No entanto, o tamanho da grade desses modelos é de cerca de 200 a 100 km, sendo comprometida a capacidade de representar os recursos locais, como topografia, bacias hidrográficas e encostas nas simulações realizadas por esses MCGs (CHOU *et al.*, 2014a).

Para estudos de escala local, como em bacias hidrográficas, é exigida uma resolução espacial mais detalhada, assim, surgem os modelos climáticos regionais (MCRs), que se baseiam nos modelos globais, porém realizam uma redução de escala (*downscaling*), ou seja, aplicam um modelo dinâmico regional ou técnicas empíricas para transferir as informações meteorológicas em baixa resolução espacial para escala de maior detalhamento (CHOU *et al.*, 2014a; ZORITA; VON STORCH, 1999). Dessa forma, é possível obter um melhor resultado nas estimativas das mudanças climáticas em termos locais.

Os MCRs têm resolução espacial entre 10 e 50km, o que permite um maior detalhamento nas estimativas das variáveis climatológicas em escalas de bacias hidrográficas médias e pequenas, desempenhando um papel importante na redução de escala de simulações climáticas globais para tamanhos de grade menores na área em que os estudos de impacto podem ser realizados (CHOU *et al.*, 2014b; MARENGO *et al.*, 2012).

O modelo Eta é um modelo atmosférico de última geração usado para fins operacionais e de pesquisa, descendente do modelo anterior do HIBU (Instituto Hidrometeorológico e Universidade de Belgrado), desenvolvido nos anos setenta na ex-Iugoslávia (MESINGER; JANJUC, 1974). Nos anos 80, o código foi atualizado e reescrito para usar a coordenada Eta vertical (MESINGER, 1984) e, posteriormente, no Centro Nacional de Previsão Ambiental dos Estados Unidos “*The United States National Centers for Environmental Prediction*” (NCEP) com uma física avançada. Tornou-se oficialmente operacional no NCEP em 8 de junho de 1993 (BLACK, 1994; MESINGER *et al.*, 1988). Em suas várias versões, o modelo foi e/ou é amplamente utilizado em vários países, incluindo Argélia, Argentina, Bélgica, Brasil, Camarões,

China, Costa Rica, Chipre, República Tcheca, Dinamarca, Egito, Finlândia, Alemanha, Grécia, Islândia, Índia, Israel, Itália, Malta, Tunísia, Turquia, Peru, Filipinas, Sérvia e Montenegro, África do Sul, Espanha, Suécia e Estados Unidos.

No Brasil, é utilizada a versão modelo regional Eta, chamado de Eta-CPTEC. Foi instalado desde 1996 no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE), para fornecer previsões meteorológicas na América do Sul. Devido à sua coordenada vertical (MESINGER, 1984), o modelo Eta é capaz de produzir resultados satisfatórios nas regiões que contêm orografia íngreme como a Cordilheira dos Andes (CHOU *et al.*, 2012).

Atualmente, foram desenvolvidas no Brasil ferramentas para ter acesso aos cenários de mudanças do clima regionalizados no país, de modo a facilitar e ampliar os estudos na área de mudanças climáticas. Dentre estas, surgiu a criação do PROJETA (Projeções de mudança do clima para a América do Sul regionalizadas pelo Modelo Eta), que tem como objetivo automatizar o processo de extração de disponibilização dos dados das projeções climáticas regionalizadas para o Brasil, geradas pelo CPTEC do INPE. O PROJETA permite o acesso amplo e irrestrito a diversos parâmetros climáticos disponíveis, e visa atender as demandas dos usuários por acesso aos dados das projeções climáticas, tratados e compatíveis com programas e plataformas de análises setoriais. Esta plataforma “PROJETA” pode ser acessada pelo link: projeta.cptec.inpe.br e foi desenvolvido no âmbito do Programa Políticas sobre Mudança do Clima (PoMuC), iniciativa do Ministério do Meio Ambiente (MMA) em parceria com o Ministério Federal do Meio Ambiente, Proteção da Natureza e Segurança Nuclear (BMU) da Alemanha, com o apoio técnico da Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH.

Os dados disponíveis na plataforma “PROJETA” foram gerados a partir de projeções de mudanças do clima atual utilizando dois cenários RCP4.5 (cenário otimista a intermediário) e RCP8.5 (cenário pessimista) conforme o quinto relatório de avaliação do IPCC (AR5), para o período de 2006 até 2099, desenvolvidos pelo modelo climático regional Eta (MESINGER *et al.*, 2012), estando configurado na resolução de 20 km, na área que cobre a América do Sul, a América Central e o Caribe (CHOU *et al.*, 2014a, 2014b) e na resolução de 5 km, na área que cobre o sudeste do Brasil (LYRA *et al.*, 2017), permitindo estudos a nível municipal. A redução de escala (*downscaling*) foi produzida a partir dos modelos climáticos globais, HadGEM2-ES

(COLLINS *et al.*, 2011); MIROC5 (WATANABE *et al.*, 2010), CanESM2 (ARORA *et al.*, 2011) e BESM (NOBRE *et al.*, 2013). Os dados do período histórico, também chamado de *baseline* ou referência, correspondem ao período em que se utiliza concentrações de gases do efeito estufa em valores atuais (1961 a 2005), servindo como base para as simulações de mudanças climáticas no futuro (2006 a 2099) (CPTEC/INPE; UPF).

O modelo Eta-HadGEM2-ES, é um modelo atmosférico de última geração, do tipo regional que utiliza a coordenada Eta e os dados do modelo global HadGEM2-ES como condições de contorno. O Modelo de Circulação Global HadGEM2-ES (*Hadley Centre Global Environmental Model version 2 Earth System*) (COLLINS *et al.*, 2011; MARTIN *et al.*, 2011) é um modelo em ponto de grade com resolução N96, equivalente a 1,875 e 1,275 graus de longitude e latitude, respectivamente, e 38 níveis verticais na atmosfera, chegando a cerca de 40 km de altitude; consistindo em um modelo numérico do sistema climático com base nas propriedades físicas, químicas e biológicas de seus componentes (atmosfera, oceano, gelo, superfície terrestre) e suas interações. Neste modelo HadGEM2-ES, os novos componentes adicionados são os ecossistemas terrestres e oceânicos e a química troposférica (LYRA, 2016).

O MIROC5 é um modelo japonês desenvolvido em cooperação, conhecido como Modelo de Pesquisa Interdisciplinar sobre Clima (MIROC), versão 5 (WATANABE *et al.* 2010). É espectral no componente atmosférico, com resolução T85, que é de aproximadamente 150 km na horizontal, possuindo 40 níveis atmosféricos verticais. É acoplado ao modelo oceânico COCO 4.5, com 50 níveis de profundidade e 1° de resolução horizontal (LYRA, 2016; CHOU *et al.*, 2014a).

O BESM é um modelo do Sistema Terrestre Brasileiro versão 2.3.1 desenvolvido pelo INPE, sendo do tipo espectral com truncamento de T62 (aprox. 250 km x 250 km) e 28 níveis na atmosfera, O modelo de atmosfera é acoplado ao modelo de oceano MOM4 e possui resolução variando de 0,25 graus entre 10°N e 10°S, 1 grau entre 10°N / S e 45°N / S, até a 2 graus entre as latitudes de 45°N / S e 90°N / S. Na longitude, a resolução é constante, 1 grau (NOBRE *et al.*, 2013; LYRA, 2016; CHOU *et al.*, 2014a).

Segundo Chou *et al.* (2014a) as simulações do Eta conduzidas pelos modelos Had-GEM2-ES, BESM e MIROC5 mostram que, comumente, esses modelos reproduzem as características climatológicas gerais sobre o continente da América do Sul. No que se refere as simulações de precipitação o Had-GEM2-ES tem tendência

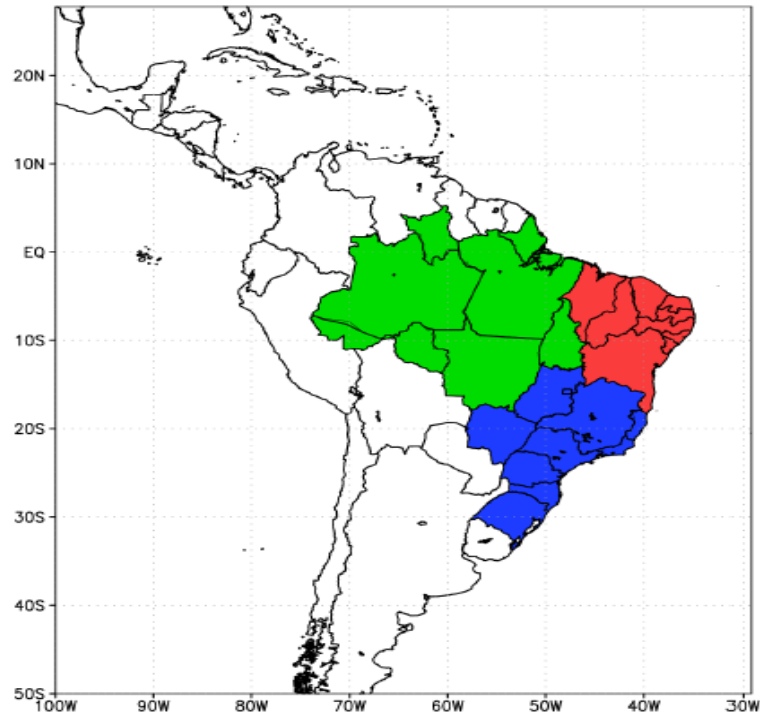
para condições mais úmidas no período, enquanto os modelos BESM e MIROC5 mostram tendências para condições mais secas.

O código do modelo regional Eta CPTEC-INPE seu código é conduzido pela coordenada vertical refinada Eta, que fica aproximadamente horizontal nas áreas montanhosas, tornando a coordenada adequada para estudos em regiões de topografia íngreme, como a Cordilheira dos Andes, na América do Sul, e esta versão utiliza um refinamento, que permite fluxos inclinados ao redor do topo das montanhas. A vantagem é que as superfícies desta coordenada são aproximadamente horizontais, o que reduz os erros nos cálculos de variáveis obtidas a partir de derivadas horizontais. Estes erros são significativos em regiões de montanhas íngremes como é o caso dos Andes na América do Sul (CHOU *et al.*, 2014a).

A dinâmica do modelo está em volume finito (JANJIC, 1984; MESINGER *et al.*, 2012), sendo que as convecções profundas e rasas são parametrizadas pelo esquema de Betts-Miller (BETTS; MILLER, 1986) modificado por (JANJIC, 1994). Já a microfísica da nuvem segue o esquema de Zhao (ZHAO; BLACK; BALDWIN, 1997). Os processos da superfície terrestre são representados pelo esquema NOAH (EK *et al.*, 2003). O modelo Eta consegue distinguir 12 tipos de vegetação e 9 tipos de solo, sendo os fluxos radiativos são tratados pelo esquema de Lacis-Hansen (LACIS; HANSEN, 1974) para ondas curtas, e pelo esquema de Fels-Schwarzkopf (FELS; SCHWARZKOPF, 1975) para ondas longas. O CO₂ é constante e mantido a 330 ppm.

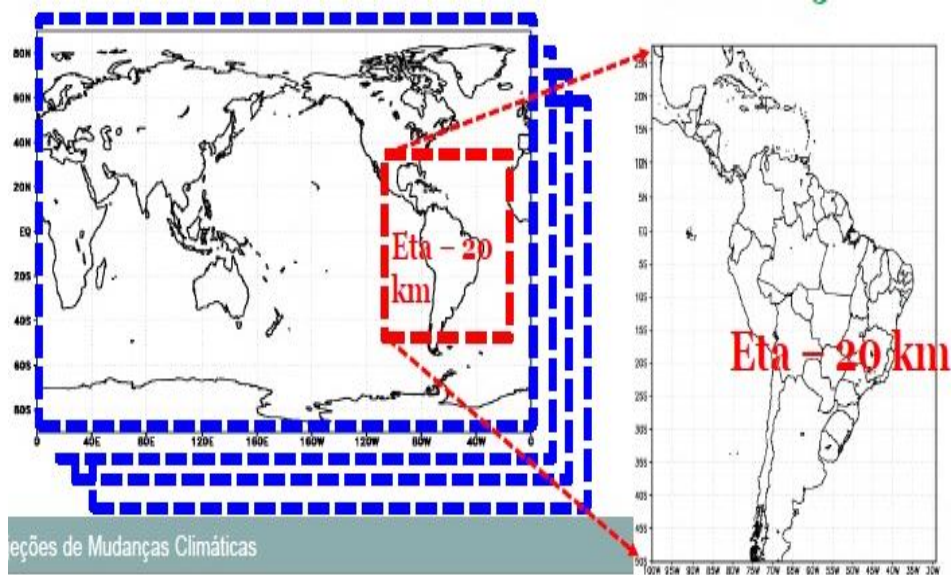
Os MCRs têm domínio na maior parte da América do Sul, América Central e parte dos oceanos adjacentes, possuindo resolução de 20 km e 38 camadas e/ou níveis verticais na atmosfera (Figura 9 e 10) (MESINGER *et al.*, 2012; CHOU *et al.*, 2014a; CHOU *et al.*, 2014b).

Figura 9 - Três grandes regiões brasileiras são destacadas nos resultados: Norte (NO-verde), Nordeste (NE-vermelho) e Centro-Sul (CSblue) do Brasil.



Fonte: CHOU *et al.*, 2014a.

Figura 10 – Resolução espacial do modelo regional Eta de 20 km.



Fonte: LYRA, 2016.

4.4 CORREÇÃO DE VIÉS

As séries de precipitação resultantes dos modelos climáticos são muito utilizadas como entrada para modelos hidrológicos para estimar as condições futuras, por exemplo de disponibilidade hídrica (OLIVEIRA, 2014), regime hidrológico de uma região de estudo, mudanças nas vazões em cursos d'água (BRÊDA, 2021), e impactos das mudanças climáticas na hidrologia e na sedimentologia de uma bacia hidrográfica (OLIVEIRA *et al.*, 2019; SANTOS *et al.*, 2021; CARVALHO *et al.*, 2022; FAGUNDES, 2022).

No entanto, os resultados de precipitação simulados de MCGs e MRGs podem apresentar grandes vieses sistemáticos em relação aos dados observados (SILLMANN *et al.*, 2013).

Erros sistemáticos nos valores simulados por modelos climáticos (globais ou regionais), principalmente dados de precipitação, podem ser resultantes de diferentes fontes como: 1- o erro pode estar atribuído ao viés sistemático nos estados atmosféricos em larga escala ou uma resposta irrealista às forças climáticas em larga escala; 2- a variabilidade gerada internamente que é imprevisível e que difere das medições *in loco* (do que realmente acontece no mundo real); 3 – causado pelas deficiências nas parametrizações de convecção e precipitação, bem como por diferenças entre a orografia real e a do modelo, considerando as condições atmosféricas (EDEN *et al.*, 2012).

Dessa forma, a correção de viés é um processo importante, possibilitando o escalonamento da saída do modelo climático, de modo a contabilizar erros sistemáticos nesses modelos (TEUTSCHBEIN; SEIBERT, 2010). Essa correção tem o objetivo de ajustar as séries temporais selecionadas de uma simulação de modelo climático para melhor corresponder às séries temporais observadas ao longo do período de referência atual (MARAUN, 2016). É muito utilizada na modelagem de mudanças climáticas, tanto para MCGs quanto para MCRs, pois, esses modelos geralmente fornecem representações tendenciosas das séries temporais observadas, tornando necessários os procedimentos de correção (CHRISTENSEN *et al.*, 2008; TEUTSCHBEIN; SEIBERT, 2010). Ao aplicar estas correções, almeja-se produzir uma melhora na qualidade dos dados simulados pelos modelos climáticos e, conseqüentemente, influenciar as simulações hidrológicas resultantes (TEUTSCHBEIN; SEIBERT, 2012).

Os métodos de correção de viés mais usualmente utilizados em estudos aplicado aos recursos hídricos e mudanças climáticas, são: abordagem de mudança delta (*Delta Change Approach*), abordagem direta (*Direct Approach*) e mapeamento de quantis (*Quantile Mapping - QM ou Quantile-Based Mapping*) (MARAUN, 2016; OLIVEIRA, 2014; TEUTSCHBEIN; SEIBERT, 2012; THEME β 1; GOBIET; HEINRICH, 2012).

O método por abordagem de mudança delta (*Delta Change Approach*) consiste em utilizar apenas a mudança sazonal prevista, entre o cenário atual e o futuro, obtidos pelo modelo climático. Essa mudança é aplicada por um fator de mudança, que consiste na razão entre o valor médio no cenário futuro (simulado pelo modelo climático) e o valor médio simulado pelo modelo climático no período de base (histórico). Essa mudança prevista é adicionada à série histórica de precipitações e de temperaturas para gerar séries no futuro (eq.1) (LENDERINK; BUIHAND; VAN DEURSEN, 2007; OLIVEIRA, 2014). A principal desvantagem é que, com essa abordagem, o padrão temporal das variáveis climáticas não será alterado para as simulações de cenários futuros (TEUTSCHBEIN; SEIBERT, 2010), ou seja, não mudará o número de dias chuvosos, a dispersão das chuvas ou os valores extremos de temperatura, pois utiliza a série histórica como base para as previsões no futuro. Assim, essa metodologia considera somente as variações dos valores médios das séries nas previsões futuras.

$$P_{cor(f)k/j} = P_{obs(b)k/j} * \left[\frac{\overline{P_{sim(f)k}}}{\overline{P_{sim(b)k}}} \right] \quad (1)$$

Onde, $P_{cor(f)k/j}$ é a precipitação corrigida no período futuro (f), no mês k e no ano j ;

$P_{obs(b)k/j}$ é a precipitação observada no período base (b), no mês k e no ano j ;

$\overline{P_{sim(f)k}}$ é a média da precipitação simulada no período futuro para o mês k ; e $\overline{P_{sim(b)k}}$ é a média da precipitação simulada no período base para o mês k .

O método de abordagem direta (*Direct Approach*) consiste na razão entre a média dos valores da série observada no período de base (dado histórico) e a média dos valores da série simulada pelo modelo climático no mesmo período de base, aplicando este valor resultante à série simulada no cenário futuro; o que possibilita corrigir as diferenças atuais do clima para as previsões no cenário futuro

(LENDERINK; BUIHAND; VAN DEURSEN, 2007; OLIVEIRA, 2014) (eq. 2). Este método tem a vantagem de considerar as mudanças desde eventos extremos a médios que acontecem no clima atual, nas previsões dos cenários futuros. Aplica o ajuste diretamente em toda a série temporal futura, incluindo a ocorrência e a intensidade de dias secos e chuvosos (VRAC; NOËL; VAUTARD, 2016).

$$P_{cor(f)k/j} = P_{sim(f)k/j} * \left[\frac{\overline{P_{obs(b)k}}}{\overline{P_{sim(b)k}}} \right] \quad (2)$$

Onde: $P_{cor(f)k/j}$ é a precipitação corrigida no período futuro (f), no mês k e no ano j ; $P_{sim(f)k/j}$ é a precipitação simulada no período futuro (f), no mês k e no ano j ; $\overline{P_{obs(b)k}}$ é a média da precipitação observada no período de base (b), para o mês k ; $\overline{P_{sim(b)k}}$ é a média da precipitação simulada no período de base (b), para o mês k .

Para as outras variáveis climáticas como, por exemplo, temperatura e evapotranspiração, Oliveira (2014) propôs a equação 3 para corrigir o viés de forma direta.

$$V_{Cor(a)i/k/j} = V_{sim(a)i/k/j} + [\overline{V_{obs(c)k}} - \overline{V_{sim(c)k}}] \quad (3)$$

Onde: $V_{Cor(a)i/k/j}$ variável climática a ser corrigida para o período de avaliação (a), no dia i , no mês k e no ano j ; $V_{sim(a)i/k/j}$ variável climática simulada no mesmo período de avaliação (a), no dia i , no mês k e no ano j ; $\overline{V_{obs(c)k}}$ é a média observada da variável climática no período de controle (c), no mês k ; e $\overline{V_{sim(c)k}}$ é a média simulada da variável climática no período de controle (c), no mês k .

Lenderink, Buishand e Van Deursen (2007) aplicaram os métodos de abordagem delta e o de abordagem direta para as correções de viés nos modelos hidrológicos no presente (1960 a 1989) e em um futuro projetado (2070 a 2099), utilizando dados meteorológicos de uma simulação de 90 anos (conjunto de três de 30 anos cada) com o modelo climático regional HadRM3H. Ambos os métodos preveem uma resposta semelhante na vazão média anual, mostrando um aumento de 30% no inverno e uma diminuição de 40% no verão. No entanto, as previsões de vazão extremas diferem significativamente, com aumentos de 10% na vazão com um

período de retorno de 100 anos na abordagem direta, e de aproximadamente 30% na abordagem delta. Estes resultados apontam para a necessidade de métodos que sejam capazes de lidar melhor com os eventos extremos.

O método original de mapeamento baseado em quantis (*Quantile-based mapping CDF matching* - CDFm) (PANOFSKY e BRIER, 1968), mapeia a distribuição de variáveis mensais (precipitação e temperatura) simuladas pelos modelos climáticos globais e regionais para a escala dos dados observados em grade, mediante o cálculo (para cada valor simulado no futuro) da probabilidade correspondente, seguido do cálculo do valor correspondente a esta probabilidade segundo a inversa da função CDF (função de probabilidade acumulada), obtida para a série de dados observados (no período de controle). O método pode ser escrito para uma variável climática X (eq.4), a qual pode ser descrita como sendo uma conversão de escala de X_{m-p} para a escala dos dados observados, em cada probabilidade acumulada individual.

$$\tilde{X}_{m-p.adjst.} = F_{o-c}^{-1} \left(F_{m-c} (X_{m-p}) \right) \quad (4)$$

Onde: F é a CDF (ajustada pela função Gama) de qualquer das observações (o) ou modelo (m), para um período de treinamento histórico ou clima atual ou corrente (c) ou período de projeção futura (p).

O CDFm proporciona o ajuste de todos os momentos (ou seja, toda a distribuição corresponde à das observações para o período de treinamento), mantendo a correlação de classificação entre modelos e observações. No entanto, uma suposição subjacente do método é que a distribuição climática não muda ao longo do tempo, ou seja, é estacionária na variância e enviesamento da distribuição, ocorrendo alteração apenas na média.

O método de correspondência equidistante (*The equidistant CDF matching method* – EDCDFm), proposto por Li, Sheffield e Wood (2010), incorpora informações do CDF da projeção do modelo em vez de assumir que a distribuição histórica do modelo se aplica ao período futuro. Para uma determinada probabilidade acumulada, à conversão de escala da equação 4 é adicionada à diferença correspondente entre o valor previsto pelo modelo climático (X_{m-p}) e o resultado da conversão de escala deste valor para a escala dos dados simulados no período corrente ($X_{m-p} - F_{m-c}^{-1}(X_{m-p})$), resultando na equação 5, de forma que a mudança da escala do modelo climático do período histórico para o período futuro também é considerada.

$$\tilde{X}_{m-p.adjust.} = X_{m-p} + F_{o-c}^{-1} \left(F_{m-p} (X_{m-p}) \right) - F_{m-c}^{-1} \left(F_{m-p} (X_{m-p}) \right) \quad (5)$$

Onde: F é a CDF de qualquer das observações (o) ou modelo (m) para um período de treinamento histórico ou clima atual (c) ou período de projeção futura (p).

Segundo Li, Sheffield e Wood (2010) o método EDCDFm considera explicitamente as mudanças na distribuição do clima futuro, incluindo as caudas da distribuição, que são mais importantes para estudos de avaliação e impacto climático, além de ser muito direto e simples de usar. Os autores argumentam que o uso de CDFs empíricas é ineficiente por fazer uso de muitas interpolações e extrapolações, preferindo o uso de funções de probabilidade. Em sua aplicação (para a vasta região do norte da Eurásia), as CDFs de precipitações mensais foram representadas por funções Gama ajustadas aos dados e aos valores gerados pelos modelos climáticos.

Os métodos de mapeamento quantil podem ser classificados em métodos paramétricos ou não paramétricos. Os paramétricos utilizam funções de distribuição de probabilidade e os não paramétricos ou empíricos utilizam distribuições de frequência, sob forma de tabelas de duas colunas (“*look-up tables*”).

A utilização dessas abordagens ainda está em discussão entre a comunidade científica (TENG *et al.*, 2015), mas a abordagem não paramétrica tem sido a mais comum. LAFON *et al.* (2013) compararam QM não paramétrico e paramétrico e concluíram que a abordagem empírica foi a mais precisa.

Cannon, Sobie e Murdock (2015) e Gudmundsson (2012) também preferem utilizar o QM empírico pelos bons resultados apresentados Themeßl, Gobiet e Heinrich (2012) apontam que a QM paramétrica pode introduzir novas imprecisões, pois a distribuição de uma variável meteorológica não é totalmente conhecida e depende da região e estação do ano, além de apresentar dificuldades para ajuste de funções quando grande parte dos dados são nulos. No entanto, o QM não paramétrico depende mais do período de calibração do que o QM paramétrico.

Switanek *et al.* (2017) argumentam que a correção de extremos é mais robusta com uma abordagem paramétrica, pois o nível de retorno do evento mais extremo é um tanto aleatório. Isso pode ser melhorado ajustando uma função às distribuições. Os autores utilizam um método (SQM – Scaled Quantile Mapping) semelhante ao de Li et al (2010), com o uso da função Gama ajustada, que apresenta melhor

desempenho para a correção de viés de dados diários GCM para a Europa, no período futuro (2071-2100).

Segundo Cannon, Sobie e Murdock (2015), os métodos não paramétricos, para grande quantidade de dados (mais de 20 anos) produzem resultados precisos e dispensam ajustes, comparativamente a modelos que serão sempre aproximações. Porém, possuem a desvantagem de não admitirem extrapolações fora do domínio.

Teutschbein e Seibert (2012) aplicaram diferentes métodos de correção de viés, entre eles, abordagem delta e mapeamento de distribuição (*Distribution Mapping*) para as variáveis precipitação e temperatura simuladas por um modelo climático regional (RCM), nas análises de simulações hidrológicas da vazão média mensal. Os autores verificaram a importância da correção de viés das séries temporais simuladas de temperatura e de precipitação de RCM, obtendo uma melhoria das séries brutas de temperatura e precipitação da RCM para as condições climáticas atuais com todas as abordagens de correção de viés. A maioria dos métodos conseguiu corrigir os valores médios diários, mas apenas abordagens mais complexas, como o mapeamento de distribuição (utilizando a função Gama ajustada para representar as CDFs de precipitações mensais, tanto para as simulações de precipitação com modelos climáticos quanto para as precipitações observadas), mostrou-se capaz de corrigir outras propriedades estatísticas, como a variância ou os quantis extremos.

Oliveira (2014) em sua pesquisa sobre a investigação dos possíveis efeitos das mudanças climáticas na disponibilidade hídrica e nas alterações na demanda hídrica no futuro, utilizou quatro métodos (*Delta Change Approach*, *Direct Approach*, *Quantile-Based mensal* e *Quantile-Based trimestral*) para a correção de viés em simulações de cenários futuros. Os resultados obtidos mostraram que os métodos de correção dos dados de precipitação que melhor originou os cenários de vazão, em relação à vazão média de longo período, foram os métodos *Quantile-Based* mensal e o trimestral com erro médio de 8,4% e 9,5%. Já os métodos *Delta* e *Direct* obtiveram um erro médio superior, sendo igual a 15%.

Lehner, Nadeem e Formayer (2021) revisaram os métodos existentes e apresentaram o método chamado EQA (Empirical Quantile Adjustment), como um desenvolvimento não paramétrico do EDCDFm (LI; SHEFFIELD; WOOD, 2010) e de uma versão multiplicativa, também paramétrica, chamada PresRAT (PIERCE *et al.*, 2015), comparando os métodos com o uso de precipitações diárias observadas e

simuladas. Os autores empregaram uma abordagem não paramétrica e multiplicativa para o método original, a qual consideram mais adequada para dados de precipitações, utilizando tratamento diferente para dias secos (chuva zero) para evitar divisões por zero durante ajustes. Essa análise é representada na equação 6 (usando a mesma simbologia da equação 6):

$$\begin{aligned} \tilde{X}_{m-p,ajustado} &= 0 && \text{se } X_{m-p} < 0,1 \text{ mm} \\ \tilde{X}_{m-p,ajustado} &= X_{m-p} * F_{o-c}^{-1} \left(F_{m-p}(X_{m-p}) \right) / F_{m-c}^{-1} \left(F_{m-p}(X_{m-p}) \right) && \text{se } X_{m-p} \geq 0,1 \text{ mm} \end{aligned} \quad (6)$$

Os termos de correção de X_{m-p} são determinados previamente, para 100 percentis equidistantes, entre 0,5% e 99,5%, constituindo um detalhamento suficiente, que ainda preserva alguma resistência com respeito à incerteza decorrente da aleatoriedade dos valores singulares extremos. São realizadas aplicações do modelo para correção de viés de precipitações GCMs simuladas para a Áustria, obtendo resultados mais favoráveis, em comparação com uma versão empírica do método CDFm e o método paramétrico SQM com diferentes alternativas para o ajuste da função Gama.

São poucos as pesquisas que aplicam estes métodos na abordagem da modelagem hidrossedimentológica envolvendo mudanças climáticas e escala temporal diária ou mensal. Um exemplo importante é a pesquisa de Oliveira *et al.* (2019), onde foi utilizado o método de escalonamento linear, proposto por Lenderink, Buishand e Van Deursen (2007), para os dados de precipitação e temperatura gerados pelos modelos regionais Eta-HadGEM2-ES, Eta-MIROC5, Eta-BESM e Eta-CANESM2, com o intuito de investigar os impactos das mudanças climáticas na hidrologia e sedimentologia em uma bacia de cabeceira do rio Paranaíba, localizado no bioma Cerrado. O método utilizado, porém, ajusta os valores médios mensais com base apenas nas diferenças entre os dados observados e os simulados pelo MCRs, desconsiderando a correção da frequência de dias úmidos.


Métodos mais avançados, como o EQA, permitem a correção de viés também de eventos extremos, e são capazes de reconstituir momentos de maior ordem, além das médias. Este método atesta a importância da abordagem empírica, todavia, limita a precisão máxima que pode ser obtida a um número estabelecido de percentis, além do espaçamento regular. Existe, portanto, espaço para a experimentação a partir desta abordagem, para além destas limitações.

4.5 MODELO DE REDE NEURAL ARTIFICIAL (RNA)

As RNAs são modelos empíricos, baseados no funcionamento do cérebro humano, compostas de neurônios artificiais, que recebem e somam estímulos, e transmitem um sinal correspondente; sendo a soma dos estímulos ponderada segundo pesos chamados de “pesos sinápticos”, em analogia com as redes naturais (ACCESS, 2000).

McCulloch e Pitts (1943) representaram, pela primeira vez, o funcionamento dos neurônios biológicos em formas matemáticas, por meio de funções lógicas e simplificadas, obtendo uma primeira representação do funcionamento dos neurônios artificiais. O modelo de McCulloch e Pitts (1943) descreve matematicamente, n terminais de entrada, representando os dendritos (parte do neurônio natural), que recebem x_1, x_2, \dots, x_n , que representam as ativações dos neurônios anteriores, e apenas um terminal de saída y (axônio). As conexões sinápticas são representadas pelos pesos w_1, w_2, \dots, w_n , cujos valores podem ser negativos ou positivos, dependendo de as sinapses serem inibitórias ou excitatórias. Sabe-se que um neurônio natural dispara quando recebe uma soma de impulsos que ultrapassa o seu limiar. Para representar este comportamento de forma artificial, o mecanismo utilizado é a comparação da soma ponderada das entradas como o limiar do neurônio, o qual, se ultrapassado, provoca o “disparo” do neurônio, com saída 1, e zero em caso contrário (MCCULLOCH; PITTS, 1943). A função limiar de McCulloch e Pitts (1943) constitui uma função de ativação, e a descrição do modelo, com a correspondente biológica, é representada na figura 11.

Figura 11 - Representação do funcionamento do neurônio de McCulloch e Pitts, Σ (soma ponderada das entradas, $f(u)$ é a função de ativação e Θ é o limiar de ativação do neurônio.



Fonte: Adaptação de BRAGA; CARVALHO; LUDERMIR, 2011.

Com o mesmo intuito dos processos neurais naturais, em 1958 surgiu a primeira rede neural artificial aplicável a problemas práticos, proposta por Rosenblatt (1958), o *Perceptron*, que constituiu um modelo computacional inspirado na retina do olho humano, com estrutura simples com apenas uma camada.

No *Perceptron* original (ROSENBLATT, 1958), a função de ativação é a função limiar, e todas as entradas e saídas são representadas por zero ou um, de forma que classificações precisam ser realizadas com uso de representações binárias. Esta foi a primeira rede neural que contou com um algoritmo para o treinamento, deduzido a partir da álgebra vetorial. O nome *Perceptron*, a partir de então, passou a ser utilizado para referir-se também a outras redes neurais de uma camada.

Widrow e Hoff (1960), propuseram um método de treinamento, chamado de regra delta, permitindo a aplicação do *Perceptron* para as saídas no domínio dos


números reais, e com funções de ativação contínuas, lineares, ou não lineares constituindo a base para a solução de problemas mais complexos. A regra delta baseia-se no treinamento do gradiente descendente no sentido de diminuir o valor da função de erro, a qual devem convergir para um mínimo, resultando pesos sinápticos ótimos. Esta regra pode ser descrita pela equação 7.

$$\mathbf{W}_{k+1} = \mathbf{W}_k + (\tau \cdot \mathbf{e}_k \cdot \boldsymbol{\delta}_k \cdot \mathbf{P}_k) \quad (7)$$

Onde: \mathbf{W} são os pesos sinápticos; τ é a taxa de aprendizado; \mathbf{e}_k são os erros das saídas; \mathbf{P}_k é a entrada na própria camada e $\boldsymbol{\delta}_k$ é a derivada das funções de ativação.

Minsky e Papert (1969) demonstraram limitações importantes sobre o modelo *Perceptron*, que na sua estrutura simples de apenas uma camada, não era capaz de detectar paridade, conectividade e simetria, ou seja, problemas não-linearmente separáveis (Figura 12). Rumelhart, Hinton e Williams (1986) apresentam uma generalização da regra delta, a qual permite o treinamento de Perceptrons de múltiplas camadas (MLP – “*Multilayer Perceptron*”).

Figura 12 – Exemplificação da classificação de padrões linearmente separáveis (A) e não-linearmente separáveis (b).



Fonte: Adaptação de SILVA; SPATTI; FLAUZINO, 2010).

O algoritmo conhecido como retropropagativo de Rumelhart, Hinton e Williams (1986), é capaz de treinar as redes de múltiplas camadas através da generalização da regra delta (WIDROW; HOFF, 1960), mediante o cálculo dos erros gerados pela última camada (saída) para cada neurônio de saída e sua retropropagação sucessiva

para as camadas anteriores. A equação 8 descreve matematicamente o cálculo da retropropagação dos erros proposto por Rumelhart, Hinton e Williams (1986).

$$e_h = \sum (W_s \cdot e_s \cdot \delta_s) \quad (8)$$

Onde: e_h é o erro na camada anterior; W_s são os pesos sinápticos na camada de saída; e_s são os erros na camada de saída e δ_s é a derivada da função de ativação na camada de saída.

Os autores apresentaram ainda um termo adicional (*momentum*) (eq. 9) para aceleração do treinamento, o qual efetivamente filtra as oscilações da trajetória, que ocorrem com taxas de treinamento altas, atuando de forma a reduzir as oscilações excessivas, e conduzindo para a solução de forma mais direta, pois cada peso sináptico recebe um impulso proporcional à magnitude da própria variação observada no ciclo anterior.

$$\Delta W_t = -\tau \cdot \delta \cdot P + m_0 \cdot \Delta W_{t-1} \quad (9)$$

Onde: ΔW_{t-1} é o passo aplicado no ciclo anterior; e m_0 termo do momento.

As redes neurais artificiais basicamente aplicam-se a problemas em que existem dados, experimentais ou gerados por meio de modelos, para os quais a rede adaptará os seus pesos visando à execução de uma determinada tarefa.

O teorema da existência, de Hecht-Nielsen (1987), expressa que "Dada uma relação contínua $r: [0, 1]^n \rightarrow \mathbf{R}^m$, existe uma rede neural artificial, com uma única camada interna e com $2n + 1$ neurônios artificiais nesta camada, a qual pode aproximá-la exatamente". O teorema da aproximação universal de Hornik, Stinchcombe e White (1989), por sua vez, estabelece que as redes neurais artificiais são capazes de aproximar relações de interesse prático, para qualquer grau de precisão desejado, complementando o teorema da existência. O teorema de Hornik, Stinchcombe e White (1989) estabelece que "dada relação mensurável $r: \mathbf{R}^n \rightarrow \mathbf{R}^m$, existe uma rede neural, com uma única camada interna, a qual pode, desde que com um número compatível de neurônios artificiais nesta camada e adequadamente treinada, aproximá-la com qualquer precisão desejada".

As redes neurais MLP, aproximadores universais, tendem, quando possuem muitos graus de liberdade (neurônios internos) e são excessivamente treinadas, a

reproduzir exatamente as amostras de treinamento, porém, perdendo a capacidade de generalização para uso em amostras diferentes. Hecht-Nielsen (1990) recomenda o uso do método da Validação Cruzada para superar esta dificuldade.

Este método consiste em separar, além da amostragem que será submetida para treinamento, uma amostragem adicional, chamada de amostragem de validação, para, durante o treinamento, avaliar, a cada ciclo, o desempenho do modelo a situações diferentes daquelas representadas na amostragem de treinamento. Desta forma, pode-se identificar o ciclo de treinamento a partir do qual o desempenho com dados diferentes daqueles do treinamento passa a diminuir, embora o desempenho com as amostras de treinamento continue melhorando. A partir deste ciclo, tem-se o sobreajustamento, devendo-se interromper o procedimento (HECHT-NIELSEN, 1990).

Uma vez que uma verificação final da capacidade de generalização do modelo deve ser realizada com uma amostragem que não tenha participado de nenhum procedimento decisório anterior (HECHT-NIELSEN, 1990), esta deve ser efetivada com uma terceira amostragem, a amostragem de verificação. Além disso, a amostragem de treinamento deve ser representativa de todo o espaço amostral disponível e, portanto, todos os registros que contém extremos de cada variável, de entrada ou de saída do modelo, deve ser realocada, se for o caso, para a amostragem de treinamento.

Os métodos de treinamento das RNAs iniciam pela adoção de pesos sinápticos aleatórios, o que produz uma rede neural diferente para cada treinamento efetuado, pois mesmo o método da validação cruzada pode, a cada treinamento, estacionar em um diferente ponto de mínimo erro na amostra de validação. Para contornar este efeito, costuma-se repetir o treinamento um certo número de vezes, adotando-se a rede que apresentou a melhor estatística de desempenho com a amostra de validação. O método da validação cruzada requer que as amostras disponíveis sejam divididas em três conjuntos amostrais, usualmente 50% para treinamento, 25% para validação e 25% para verificação (HECHT-NIELSEN, 1990).

No entanto, trabalhos recentes como de Silva (2019), de Gambim (2019) e de Finck (2020) demonstraram que a divisão clássica entre as proporções, para as amostras de treinamento, validação e verificação, nem sempre é adequada. Finck e Pedrollo (2021) propuseram a noção de quantidade de informação como critério, em oposição à da quantidade de registros de dados. Ou seja, o acréscimo de dados, sem

correspondência com o acréscimo de informação, não contribui para o treinamento, podendo até mesmo prejudicá-lo, pois registros repetidos ou semelhantes (geralmente ocorrências mais triviais) equivalem a impor ponderação maior justamente a estes, prejudicando a representatividade dos demais registros na aplicação da regra de treinamento.

Com respeito à arquitetura da MLP, um aspecto fundamental é a decisão da complexidade, a qual compreende o número de neurônios internos. Tem-se adotado nos trabalhos de Lucchese, Oliveira e Pedrollo (2020), Teixeira *et al.* (2020); Campos e Pedrollo (2021); Finck e Pedrollo (2021) a estratégia de buscar o número de neurônios da rede cujo desempenho com a amostra de validação, quando a rede é treinada sem sobreajustamento, é semelhante ao desempenho de uma rede propositadamente superdimensionada. Esta complexidade representa o limiar abaixo da qual o desempenho cai substancialmente, significando que não existem graus de liberdade suficiente para a aproximação desejada (CAMPOS, 2019; LUCCHESE; OLIVEIRA; PEDROLLO, 2020).

4.5.1 Aplicação de modelos de rede neural artificial (RNA) na área hidroambiental

Os modelos de RNAs vêm sendo aplicados para solucionar problemas na área hidroambiental, envolvendo desde estimativas de vazões (MATOS; PEDROLLO; CASTRO, 2014; OLIVEIRA; PEDROLLO; CASTRO, 2014; SHOAI B *et al.*, 2018), teor de umidade no solo (OLIVEIRA *et al.*, 2017; BARTELS *et al.*, 2021), preenchimento de falhas de séries temporais de chuva (DEPINÉ *et al.*, 2014), estimativas de descarga sólida em suspensão (QSS) (LAFDANI; NIA; AHMADI, 2013; AFAN *et al.*, 2015; ADIB; MAHMOODI, 2017; BUYUKYILDIZ; KUMCU, 2017; PEKTAS; CIGIZOGLU, 2017; UCA *et al.*, 2018; CHOUBIN *et al.*, 2018) e produção de sedimentos em suspensão (PSS) (YADAV *et al.*, 2022), tendo sido demonstrada a viabilidade da utilização destes modelos.

Na pesquisa de Oliveira, Pedrollo e Castro (2014), que avaliaram modelos de RNAs na estimativa de vazão média mensal em uma bacia hidrográfica do rio Ijuí (área de 5.414 Km²), foram utilizadas, como dados de entrada, séries brutas de precipitação e evapotranspiração e também séries transformadas por médias móveis exponenciais (MME). Estes modelos foram treinados com o algoritmo retropropagativo e validação

cruzada e tiveram resultados bastante significativos como: melhores desempenho (NS igual a 0,904) para os modelos com menos dados de entrada inseridos (3 variáveis) e menor número de neurônios internos (16 neurônios), onde as variáveis de entradas com maior influência nos desempenhos foram as transformadas pelas MME.

Os modelos de RNAs já apresentam um desempenho diferente para as estimativas de QSS, como demonstrado por Choubin *et al.* (2018) que avaliaram diferentes modelos, entre eles, o modelo MLP com algoritmo de treinamento Lavenburg-Marquard, para a estimativa de QSS na bacia de Haraz (Irã), com área de drenagem igual a 4.014 Km². Os autores utilizaram como variáveis de entrada a descarga sólida em suspensão, a vazão, a precipitação e o nível de água mensal em um período de 1981 a 2010, e obtiveram um desempenho satisfatório, porém abaixo daqueles observados para modelos hidrológicos (OLIVEIRA; PEDROLLO; CASTRO, 2014; SHOAI B *et al.*, 2018), alcançando NS igual a 0,52. Já UCA *et al.* (2018), com o mesmo modelo e algoritmo de treinamento, encontraram NS igual a 0,98 para uma bacia da Malásia (20,51 Km²), demonstrando que os modelos de RNAs são capazes de estimar cargas de sedimentos em suspensão nestas bacias.

Outra aplicação das RNAs, que está sendo explorada, é a previsão de concentração de sedimentos em suspensão (CSS), tendo sido recentemente pesquisada por Bayram, Kankal e Önsöy (2012), Sari, Castro e Pedrollo (2017), Campos (2019), Teixeira *et al.* (2020) e Campos e Pedrollo (2021).

Bayram, Kankal e Önsöy (2012), verificaram que a turbidez utilizada como variável de entrada nas RNAs melhorava o desempenho dos modelos para a estimativa de CSS, obtendo erro absoluto médio (MAE) e erro médio quadrático (RMSE) para a verificação, respectivamente, igual a 11,40 mg/L e 17,87 mg/L. Demonstrando que a turbidez é potencialmente uma medida substituta viável para estimar o CSS devido à alta correlação entre a turbidez e a CSS.

Sari, Castro e Pedrollo (2017), avaliaram o desempenho das RNAs, utilizando como dados de entrada as variáveis nível do rio e vazão para a estimativa da CSS na bacia do rio Taboão (78 Km²). Nesta pesquisa foi utilizado o método da complexidade dos neurônios internos, tendo sido observado que o melhor modelo foi o que utilizou 3 neurônios. Os autores também realizaram dois tipos de treinamentos diferentes, a técnica da validação cruzada e outro pela reamostragem, ambos resultaram em bons desempenhos na verificação com NS igual a 0,788 e 0,953, respectivamente.

Khan *et al.* (2018) verificaram o desempenho das RNAs a partir de séries diárias de vazão para estimar a CSS na bacia do rio Ramganga (Índia), com área de drenagem de 22.685 Km². Os modelos de RNAs foram treinados com séries de um ano atrás de vazão (modelo 1), dois anos atrás (modelo 2) e três anos atrás (modelo 3), dividindo amostras de treinamento (75%) e verificação (25%), e variando os neurônios internos de 1 a 10. O melhor modelo resultante utilizou 8 neurônios internos em sua estrutura e dados mais recentes de vazão, com R² igual a 0,99 e erro médio quadrático (RMSE) igual a 0,0004 mg/L.

A pesquisa de Campos (2019) utilizou uma forma inovadora de trabalhar com a escassez de dados das estações de monitoramento para estimar a CSS. Em sua pesquisa, a autora realizou uma modelagem, em escala espacial, com uso de RNAs para estimar CSS em diversos pontos da porção brasileira da bacia do Alto Paraguai. O modelo de RNAs obtido estima a CSS em qualquer ponto dentro da bacia para o qual existam informações de turbidez, de vazão e de precipitação, associadas às características relativas à área de drenagem de cada ponto, tais como o tipo de solo, a declividade média, o uso do solo e a cobertura vegetal. Nos modelos foram testadas diferentes combinações de dados de entradas totalizando 53 variáveis (precipitação, turbidez, tipo de solo, vazão, cobertura vegetal, uso solo, área da bacia, declividade média). O modelo que utiliza todas as variáveis resultou em um NS igual a 0,794 na verificação, já no modelo que considerou as variáveis mais significativa (considerando o nível de significância de 5%) obteve o melhor desempenho (NS = 0,832 na verificação).

Nos estudos de Teixeira *et al.* (2020) foi desenvolvido um modelo regional baseado em RNAs para estimar a CSS e a turbidez em bacias hidrográficas agrícolas. Este modelo teve como intuito a superação da escassez de dados combinando dados de diferentes escalas de bacias hidrográficas em um único modelo. As variáveis utilizadas como entrada dos modelos foram a descarga e a turbidez, além da precipitação horária para calcular a CSS e a turbidez horária. O melhor modelo de RNAs para CSS horária foi o que utilizou como variáveis de entrada a área da bacia e a EWMA (médias móveis com ponderação exponencial da precipitação passada), resultando em um NS para as amostras de treinamento igual a 0,867 e para a verificação de 0,956.

Portanto, observa-se que a aplicação dos modelos de RNAs têm-se destacado para a abordagem de temas na área hidroambiental. No entanto, na área

hidrossedimentológica em conjunto com a temática de mudanças climáticas há muito ainda a ser explorado. Assim, esta pesquisa optou pelo uso dos modelos de redes neurais, como ferramenta para estimar a produção de sedimentos em suspensão e a tendência dessa variável em diferentes cenários de mudanças climáticas.

4.6 FILTROS DE TRANSFORMAÇÃO DE DADOS DE ENTRADA

Representar os fenômenos hidrológicos e sedimentológicos, por meio de dados observados como chuva, vazão e nível de água na modelagem computacional é muitas vezes desafiador, pois estes fenômenos possuem outros fatores que os influenciam, tais como as características físicas da bacia, o tipo de solo e o uso do solo (como mencionado no item 4.1 do referencial teórico). Por exemplo, a modelagem hidrossedimentológica, que consiste em estimar a vazão, a concentração e a produção de sedimentos em suspensão, requer a representação dos fatores (regime de chuva, características da bacia, condições antecedentes) que influenciam na geração do escoamento e do sedimento em um rio. A principal variável de entrada nestes modelos é a precipitação (chuva), pois é a variável que melhor se correlaciona com a vazão, sendo também a principal responsável pela erosão, porém esta variável não consegue representar todos os fenômenos físico envolvidos, como por exemplo as condições iniciais em que o solo se encontra, ou seja, o solo pode estar seco ou úmido, influenciando no escoamento gerado. Essas características e suas intercorrelações tornam mais complexas as análises de modelagem.

Surge, portanto, a necessidade de utilização de recursos que transformam os dados de entrada, constituindo artifícios para a agregação de dados temporais. Estas transformações podem sintetizar efeitos físicos importantes que afetam a formação de vazões e a produção de sedimentos. Os filtros utilizados com essa finalidade são a média móvel uniforme (MMU), a média móvel com decaimento exponencial (MME) e a média móvel gama (MMG). Estas agregações de dados de entrada, sobretudo aplicadas a dados de precipitação, foram e estão sendo muito utilizados por diversos pesquisadores da área, como, por exemplo, nos trabalhos de Oliveira, Pedrollo e Castro (2014), Oliveira, Pedrollo e Castro (2015), Oliveira *et al.* (2017), Campos (2019) e Finck (2020).

No filtro de média móvel uniforme (MMU) determina-se a média dos registros de dados mais recentes calculado conforme a janela móvel (j_n). Por exemplo, se a

janela for igual a 12, então, utilizando MMU, seria substituído cada precipitação no tempo “t” pela média dos últimos 11 dados e da precipitação no tempo “t”. Um recurso equivalente (porém usando precipitações acumuladas em 12 horas) foi utilizado no trabalho de Bravo *et al.* (2008) que desenvolveu modelos de RNAs para a previsão de curto prazo de vazão afluente ao reservatório de Furnas.

A média móvel com decaimento exponencial das precipitações antecedentes (MME) foi proposta por Moore (1982) para representar a umidade do solo de modelos de previsão baseados em séries de precipitação. Este recurso atribui maiores pesos para as precipitações recentes e pesos exponencialmente menores para as precipitações mais antigas. E pode ser calculado pela equação 10.

$$MME_t = (1 - \alpha) * MME_{T-1} + \alpha * P_t \quad (10)$$

$$\alpha = 1 - 0,5^{(1/mei)} \quad (61)$$

Onde: MME_t é a média móvel com decaimento exponencial no instante t; α é o coeficiente de decaimento relacionado ao tempo de meia vida (eq.11); P_t é a precipitação no instante t; mei é o tempo de meia-vida (quantidade de intervalos anteriores que corresponderam 0,5).

Este filtro foi utilizado no trabalho de Oliveira *et al.* (2017) que analisou, através dos modelos de RNA, a variação espaço-temporal do teor de umidade do solo na bacia do Taboão, utilizando a MME tanto nas variáveis de precipitação horária como diária. Neste trabalho, os autores verificaram que essa média móvel, quando aplicada como variável de entrada, resultou em maior eficiência para o modelo quando comparada ao uso de chuvas isoladas.

No trabalho de Campos (2019), que realizou a modelagem, em escala espacial, desenvolvida com RNAs para estimar a CSS em diversos pontos da porção brasileira da bacia do Alto Paraguai, foi utilizada uma variável de entrada formada pela MME para a série de precipitação. Os modelos de RNAs tiveram seus desempenhos consideravelmente melhorados.

A Média Móvel Gama (MMG) foi apresentada por Finck e Pedrollo (2021), sendo baseada na função de distribuição de probabilidade Gama, dependendo de dois parâmetros, de forma e de escala, além de um terceiro, que considera o atraso no processo de transformação chuva-vazão. Este filtro pode apresentar o mesmo

comportamento que o MME (com pesos progressivamente menores em direção ao passado), ou mesmo apresentar um aumento seguido de redução, aproveitando a variabilidade das formas assumidas pela distribuição Gama.

Finck e Pedrollo (2021) utilizaram os filtros do tipo média móvel uniforme, média móvel de decaimento exponencial, diferença móvel e média móvel gama para séries de entrada de nível de água e de precipitação nos modelos de RNAs para a previsão em tempo atual de níveis fluviais com vistas ao alerta de cheias para os postos do sistema de alerta da bacia do rio Taquari-Antas/RS. Para a série de nível de água o melhor filtro foi o de diferença móvel que obteve maior correlação com as diferenças entre o tempo atual e os alcances testados. Já na série de precipitação os melhores filtros foram os MMU e MMG, sendo preferido o MMG, por necessitar de menos dados antecedentes para horizontes menores, inclusive pelo parâmetro zero de defasagem resultante do ajuste.

4.7 ESTATÍSTICAS DE DESEMPENHO PARA MODELOS HIDROAMBIENTAIS

Para as análises de desempenho dos modelos, são aplicadas estatísticas que comparam a saída simulada com os dados observados ou medidos. Moriasi *et al.* (2015) propuseram um sistema de classificação para a avaliação do desempenho de modelos que realizam estimativas de variáveis hidrológicas, sedimentológicas e de qualidade da água, com escala temporal sazonal, diária, mensal e anual, e escala espacial de bacia hidrográfica e de campo, sendo três modelos amplamente publicados em escala de bacias hidrográficas (SWAT, HSPF, WARMF) e um modelo em escala de campo (ADAPT). As métricas propostas por estes autores, para estimativas e previsões de sedimentos foram: coeficiente de determinação (R^2), Coeficiente de Eficiência de Nash Sutcliffe (NS) e percentual bias (Pbias).

O Coeficiente de Eficiência de Nash-Sutcliffe (NS) é uma estatística que representa a proporção da variância dos dados que é explicada pelo modelo, apresentando valores entre $-\infty$ e 1 e valor ideal e/ou ótimo igual a 1 (Nash e Sutcliffe, 1970), podendo ser calculada pela fórmula a seguir (eq.12):

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (7)$$

Onde: O_i representa os valores observados, P_i representa os valores calculados ou simulados e \bar{O} é a média dos valores observados.

Moriasi *et al.* (2015) classificam os desempenhos de acordo com a escala de valores do NS sendo ‘muito bom’ ($NS > 0,8$); ‘bom’ ($0,7 < NS \leq 0,8$); ‘satisfatório’ ($0,45 < NS \leq 0,7$); ‘insatisfatório’ ($NS \leq 0,45$).

O percentual bias (Pbias) mede a tendência média dos dados simulados que podem ser maiores ou menores do que os observados. Valores positivos indicam o viés de subestimação do modelo e os valores negativos indicam viés de superestimação do modelo (GUPTA *et al.*, 1999; MORIASI *et al.*, 2015) (eq.13). O Pbias demonstra o quão bem o modelo simula as magnitudes médias para a resposta de saída de interesse e é útil para simulações contínuas de longo prazo (HARMEL *et al.*, 2010). O valor ótimo de Pbias é igual a zero, porém Moriasi *et al.* (2015), com base em vários modelos que estimavam sedimentos propôs uma classificação de valores para considerar um desempenho ‘muito bom’ ($Pbias < \pm 10$); ‘bom’ $\pm 10 \leq Pbias < \pm 15$; ‘satisfatório’ ($\pm 15 \leq Pbias < \pm 20$); ‘insatisfatório’ ($Pbias > \pm 20$).

$$P_{bias} = \frac{\sum_{i=1}^n O_i - P_i}{\sum_{i=1}^n O_i} * 100 \quad (13)$$

Onde: O_i representam os valores observados, e P_i representa os valores calculados ou simulados.

O Erro médio absoluto (Mea) é muito utilizado para a previsão de erros nas análises de séries temporais, sendo a diferença absoluta média entre os valores observados e os valores simulados. Quanto menores os valores de Mea melhores serão os desempenhos dos modelos, sendo o valor ideal igual a zero. Esta métrica funciona muito bem para simulações contínuas de longo prazo (MORIASI *et al.*, 2015) (eq.14).

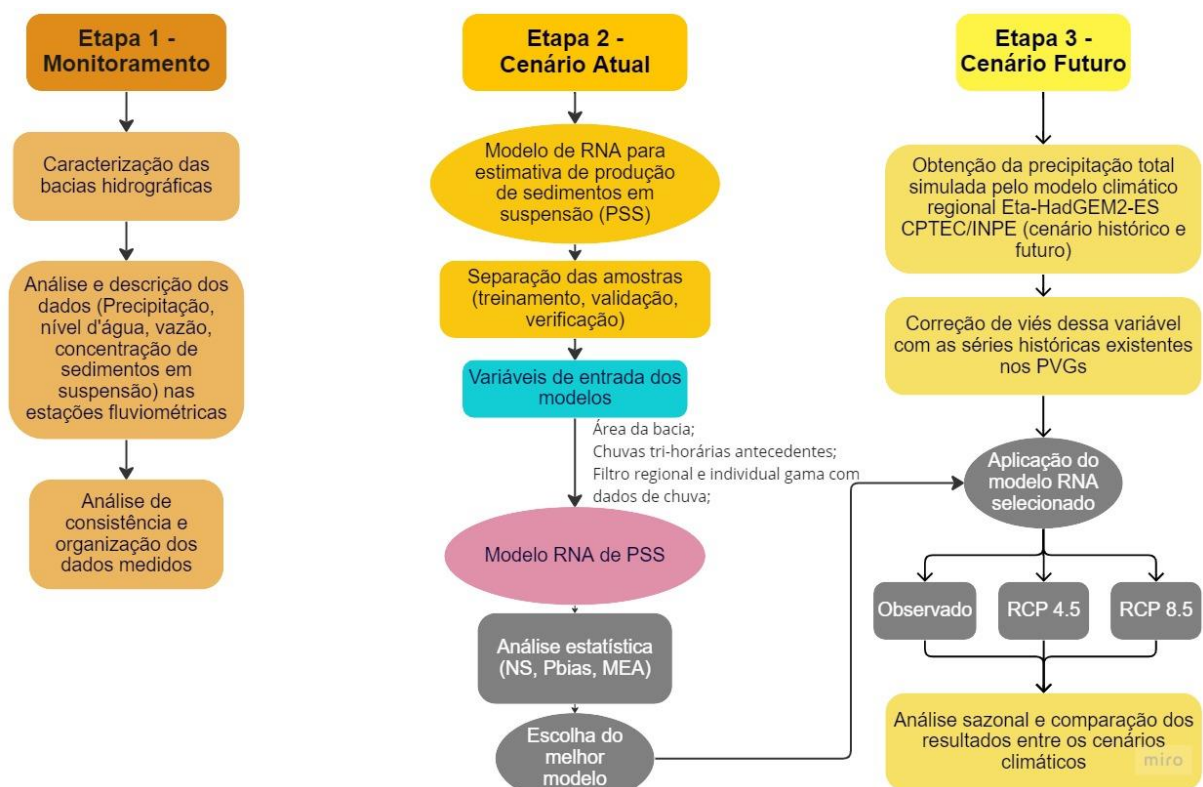
$$MEA = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (84)$$

Onde: O_i representa os valores observados, e P_i indica os valores calculados ou simulados.

5 MATERIAIS E MÉTODOS

Para a execução deste trabalho a metodologia consiste em três etapas, sendo a primeira chamada de monitoramento, onde está descrita a caracterização da área de estudo, como foi realizado o monitoramento dos dados observados, a análise e as consistências destes dados que foram utilizados nos modelos de RNAs. A segunda etapa chama-se cenário atual onde será descrito como foi realizada a estrutura e o treinamento dos modelos de RNAs tri-horários de produção de sedimentos em suspensão (PSS) e por último, a terceira etapa, chamada de cenário futuro em que são explicados como foi aplicado o modelo de RNA para estimar a PSS em dois cenários futuros de mudanças climáticas. Para melhor a visualização das etapas foi elaborado um fluxograma na Figura 13.

Figura 13 – Fluxograma das etapas da metodologia da pesquisa.



Fonte: A autora.

5.1 ETAPA 1 – MONITORAMENTO

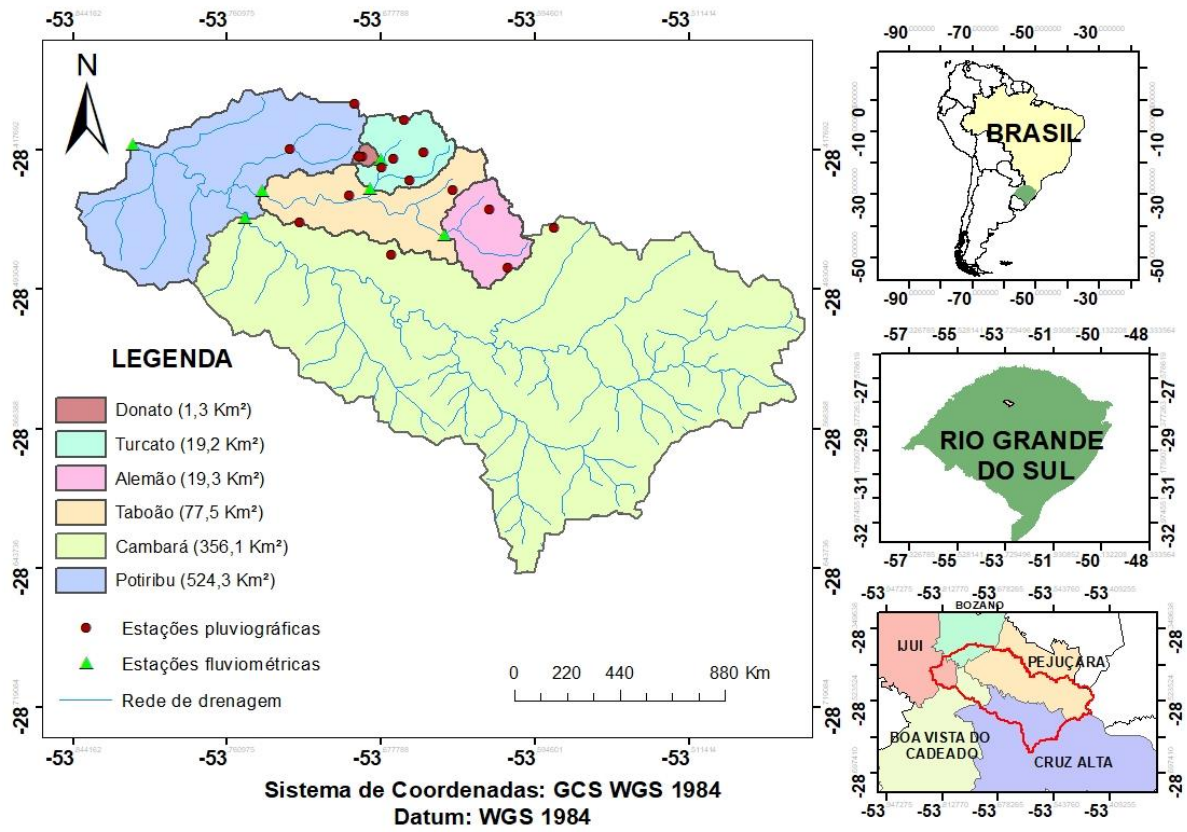
Nesta etapa da pesquisa apresenta-se a localização e a caracterização da área de estudo, bem como a descrição das variáveis utilizadas ao longo dessa pesquisa, resultantes do monitoramento nas estações fluviométricas das bacias do rio Potiribu, Cambará, Taboão, Turcato, Alemão e Donato e também das estações pluviométricas distribuídas ao longo da bacia do Potiribu.

5.1.1 Caracterização da área de estudo

A bacia hidrográfica em estudo é a do rio Potiribu, que compreende outras cinco bacias menores, que são Cambará, Taboão, Turcato, Alemão e Donato, com áreas correspondendo a 524,3 Km², 356,1 Km², 77,5 Km², 19,2 Km², 19,3 Km² e 1,3 Km², respectivamente. Estas bacias estão localizadas na região Noroeste do Estado do Rio Grande do Sul, abrangendo os municípios de Ijuí, Cruz Alta e Pejuçara (Figura 14).

As bacias caracterizam-se como rurais sendo a maior porção de área destinada para culturas anuais perenes, sendo principalmente a soja no verão, e o trigo e a aveia no inverno, todas semeadas pelo sistema plantio direto. A bacia do rio Potiribu tem 75,81% de sua área ocupada com o cultivo de soja e 6,16% de outras lavouras temporárias, Cambará tem 76,30% e 5,31%, Taboão 74,88% e 8,97%, Alemão 81,60% e 10,94%, Turcato 72,19% e 9,62% e Donato tem 89,25% e 7,98%, respectivamente. Todas as bacias possuem menos de 11% de áreas ocupadas por floresta (Tabela 3 e Figura 15).

Figura 14 – Mapa de localização das bacias hidrográficas em estudo.



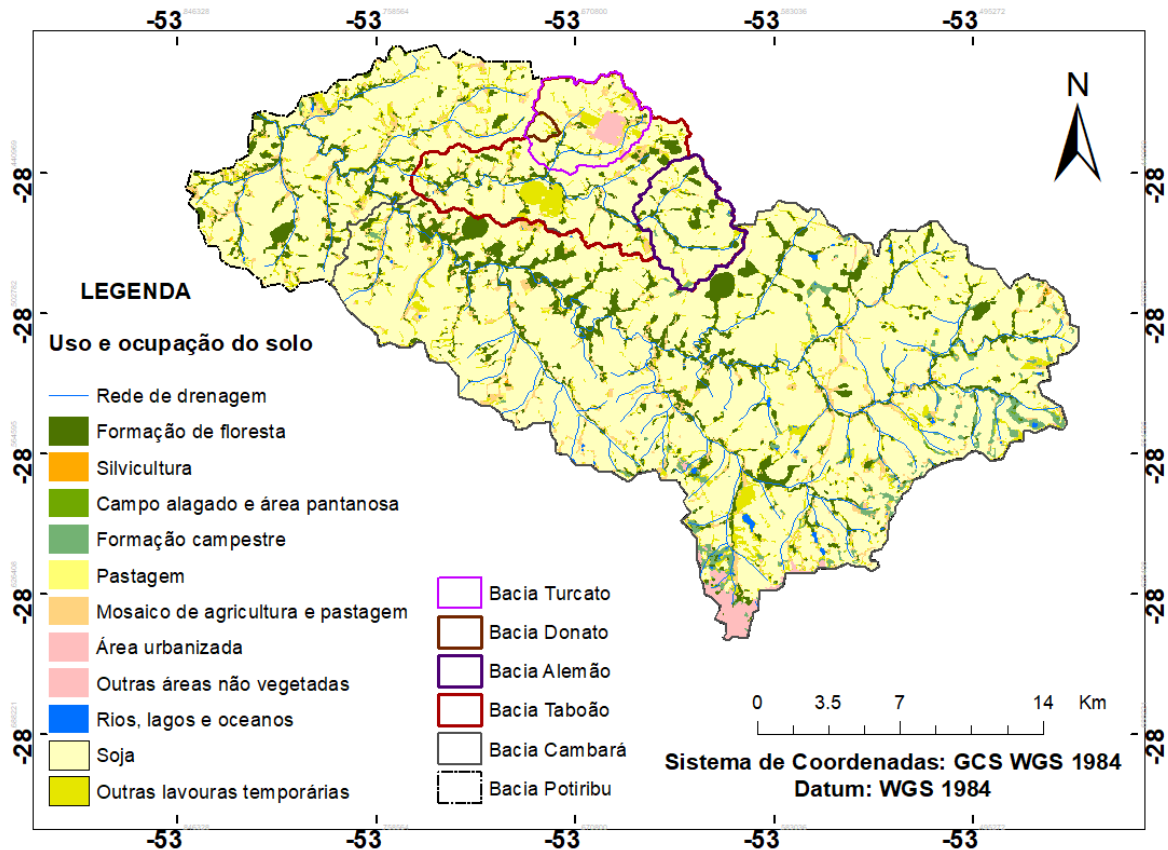
Fonte: Elaborado pela autora com o auxílio do software ArcGIS 10.3.

Tabela 3- Uso e ocupação do solo nas bacias hidrográficas em estudo.

Uso e ocupação do solo	Bacias Hidrográficas (Áreas)											
	Potiribu		Cambará		Taboão		Turcato		Alemão		Donato	
	(Km ²)	(%)	(Km ²)	(%)	(Km ²)	(%)	(Km ²)	(%)	(Km ²)	(%)	(Km ²)	(%)
Formação de floresta	52,1	9,94	35,4	9,93	7,18	9,26	0,68	3,52	2,11	10,94	0,03	2,06
Silvicultura	0,1	0,03	0,1	0,02	0,03	0,03	0,01	0,04	–	–	–	–
Campo alagado e área pantanosa	0,3	0,05	0,3	0,07	–	–	–	–	–	–	–	–
Formação campestre	8,9	1,70	8,5	2,38	0,31	0,40	0,01	0,03	0,27	1,42	–	–
Pastagem	1,9	0,37	0,9	0,24	0,21	0,27	0,10	0,52	0,01	0,03	–	–
Mosaico de agricultura e pastagem	23,9	4,57	15,0	4,22	3,19	4,12	1,18	6,12	0,29	1,49	0,01	0,71
Área urbanizada	5,3	1,00	3,8	1,06	1,44	1,85	1,43	7,47	–	–	–	–
Outras áreas não vegetadas	0,6	0,12	0,4	0,12	0,13	0,17	0,09	0,47	–	–	–	–
Rios, lagos e oceanos	1,4	0,26	1,2	0,34	0,03	0,04	0,00	0,02	0,02	0,10	–	–
Soja	397,5	75,81	271,7	76,30	58,03	74,88	13,86	72,19	15,75	81,60	1,16	89,25
Outras lavouras temporárias	32,3	6,16	18,9	5,31	6,95	8,97	1,85	9,62	0,85	4,42	0,10	7,98
ÁREA TOTAL DA BACIA	524,3	100	356,1	100	77,5	100	19,2	100	19,3	100	1,3	100

Fonte: Elaborado pela autora a partir da caracterização da área da bacia com o auxílio do software ArcGIS 10.3 e mapa do uso do solo do ano de 2020 do MapBiomas v6.0.

Figura 15 – Mapa de uso e ocupação do solo das bacias hidrográficas em estudo do ano de 2020.



Fonte: Elaborado pela autora a partir da caracterização da área da bacia com o auxílio do software ArcGIS 10.3 e mapa do uso do solo do ano de 2020 do MapBiomias v6.0.

Os solos das bacias foram classificados conforme EMBRAPA (2011), sendo que há dois tipos predominantes nas bacias em estudo: Latossolos Vermelhos Distróficos (LVd1) e Latossolos Vermelhos Distroféricos + Nitossolos Vermelhos Eutróficos (LVdf4) (Tabela 4 e Figura 16). Porém, pode-se ter outros tipos de solo nesta área, pois não foram realizados levantamentos mais detalhados para a bacia maior (Potiribu). Já na sub-bacia do Taboão existe um levantamento semidetalhado dos solos e a identificação das unidades de mapeamento, realizado na escala 1:25.000 por Carvalho *et al.* (1990). Este mapa foi reclassificado nos estudos de Viero (2004) adequando a classificação dos tipos de solos encontrados para o Sistema Brasileiro de Classificação dos Solos de 1999 da EMBRAPA, e posteriormente foi readequado novamente nos estudos de Depiné (2014) sendo classificados pelo Sistema Brasileiro de Classificação dos Solos de 2006 da EMBRAPA. Essa última classificação dos tipos de solos na sub-bacia do Taboão obteve 6 classes de solos,

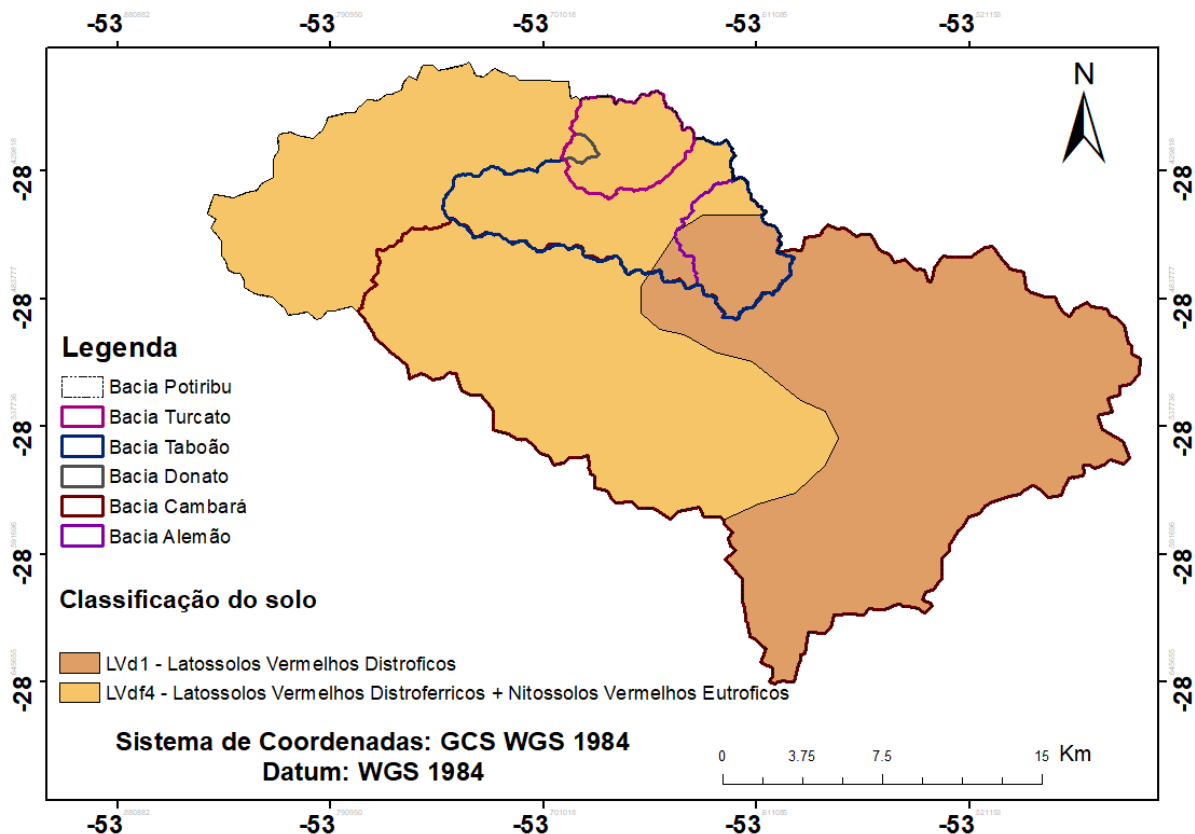
sendo: Neossolo Flúvico Tb Eutrófico (RYbe), Neossolo Litólico Eutrófico (RLe), Latossolo Vermelho Distrófico (LVd), Latossolo Vermelho Distroférico (LVdf), Nitossolo Vermelho Eutroférico (NVef) e Gleissolo Háplico (GX) (SARI, 2017).

Tabela 4 – Classificação do solo das bacias hidrográficas em estudo.

Bacias	Tipo de Solo			
	Lvd1		Lvd4	
	Área	%	Área	%
Potiribu	227,1	43,3	297,2	56,7
Cambará	209,4	58,8	146,7	41,2
Taboão	17,9	23,1	59,6	76,9
Alemão	15,6	80,8	3,7	19,2
Turcato	–	–	19,2	100,0
Donato	–	–	1,3	100,0

Fonte: Elaborado pela autora a partir da caracterização da área com o auxílio do software ArcGIS 10.3 e do mapa do tipo de solo conforme EMBRAPA 2011.

Figura 16 – Mapa de classificação do solo das bacias hidrográficas em estudo.



Fonte: Elaborado pela autora a partir da caracterização da área com o auxílio do software ArcGIS 10.3 e do mapa do tipo de solo conforme EMBRAPA 2011.

A declividade de uma área é definida como a variação de altitude entre dois pontos do terreno, em relação à distância que os separa, e tem relação direta com a

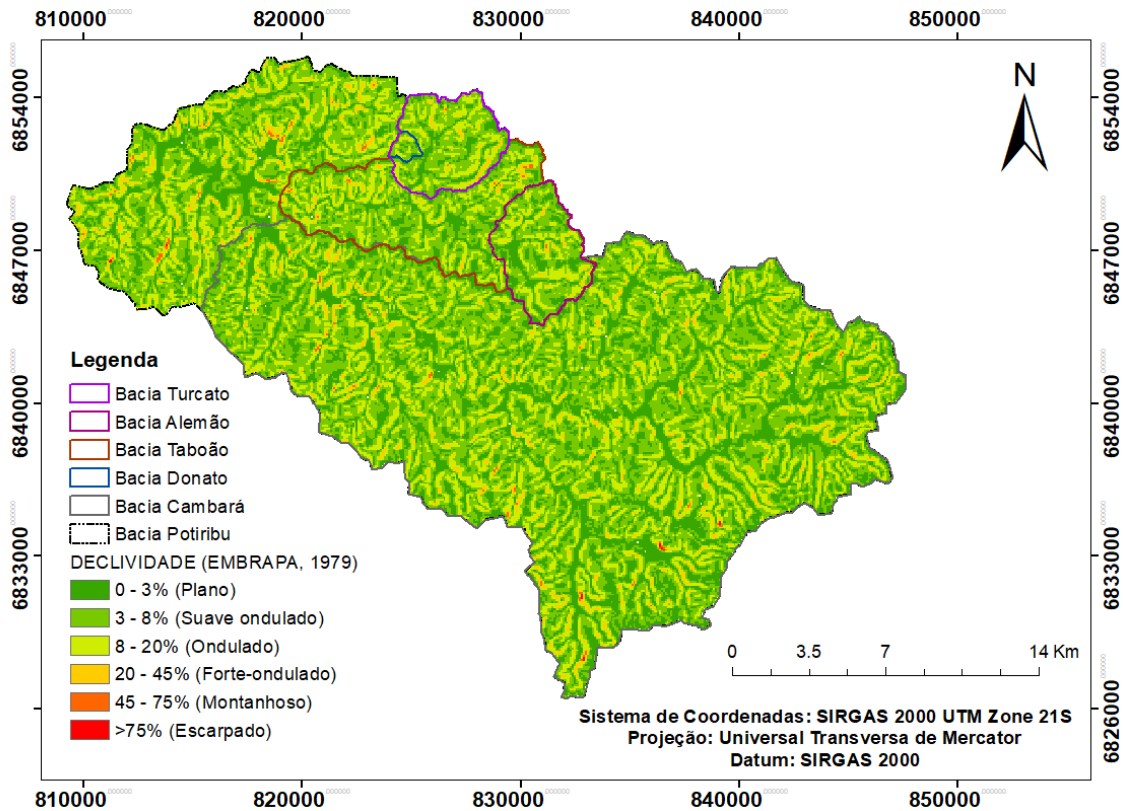
velocidade de escoamento superficial gerado por chuvas intensas, ou seja, em relevos mais íngremes ocorre um aumento do escoamento superficial e como consequência este terreno tem mais susceptibilidade à erosão, enquanto que em relevos mais planos há a redução dessa velocidade. Assim, as classes de declividade geradas nas bacias em estudo foram reclassificadas em seis intervalos distintos, conforme Embrapa (1979), sendo relevo plano (0 – 3%), suave ondulado (3 - 8%), ondulado (8 - 20%), forte-ondulado (20 - 45%), montanhoso (45 - 75%), escarpado ou fortemente montanhoso (>75%). Percebe-se que a declividade da bacia em estudo é predominantemente suave ondulado, presente em 44,25% de sua área, 26,92% com áreas onduladas e 24,61% possuindo relevo plano (Tabela 5 e Figura 17).

Tabela 5- Declividade da bacia potiribu conforme a classificação da EMBRAPA (1979).

CLASSES EMBRAPA 1979	Bacia Potiribu (Área)	
	km ²	%
Plano (0 - 3%)	129,02	24,61
Suave ondulado (3 - 8%)	232,02	44,25
Ondulado (8 - 20%)	141,14	26,92
Forte-ondulado (20 - 45%)	20,29	3,87
Montanhoso (45 - 75%)	1,66	0,32
Escarpado (>75%)	0,17	0,03
Total da área da bacia	524,3	100

Fonte: A autora.

Figura 17 – Mapa de declividade das bacias hidrográficas em estudo.



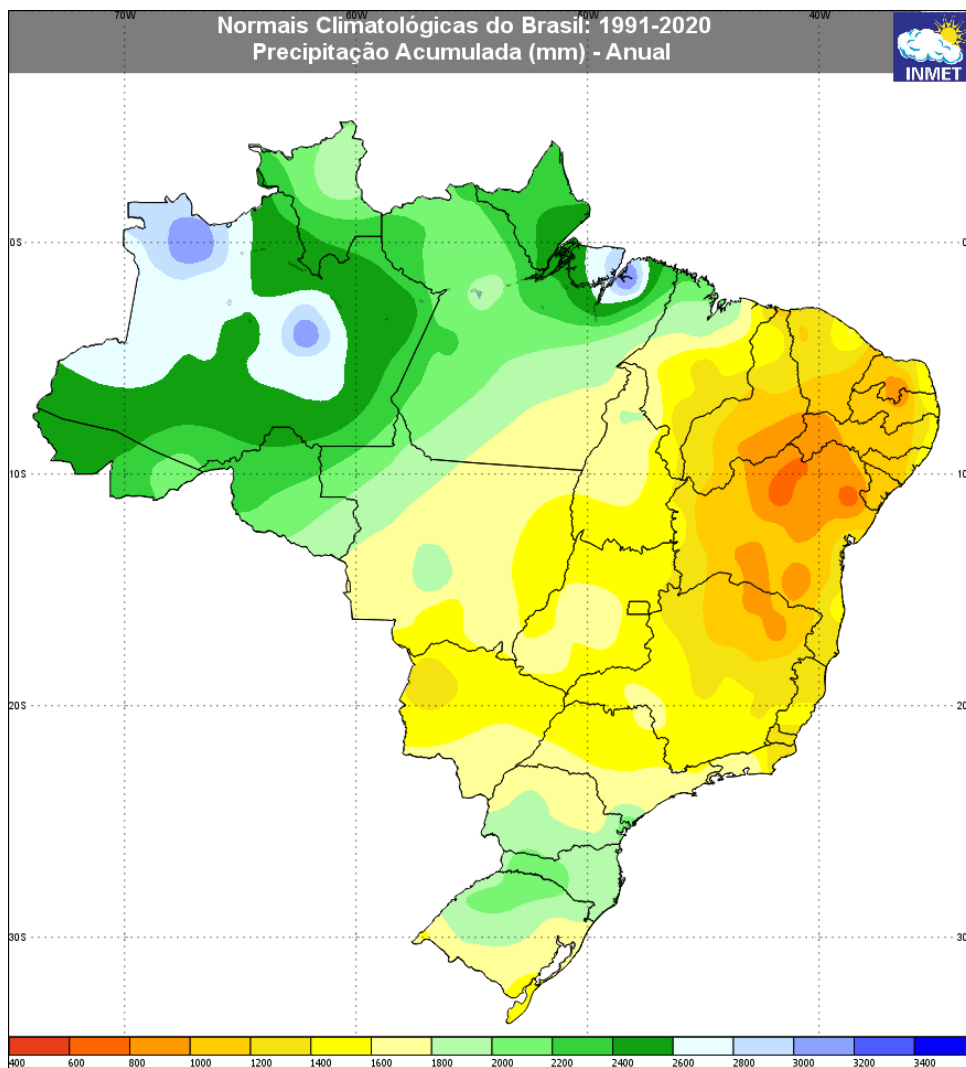
Fonte: Elaborado pela autora a partir do modelo digital de elevação (MDE) retirado do site TOPODATA (INPE), folha 28S54, com resolução espacial de 30 m x 30 m, e classificada por EMBRAPA 1979 com o auxílio do software ArcGIS 10.3.

O clima da região é classificado como subtropical úmido grupo Cfa (sempre úmido e verões quentes), conforme a classificação climática de Köppen, com temperaturas médias anuais variando de 14°C a 22°C, podendo ter temperaturas extremas abaixo de zero no inverno e máximas próximos de 40°C no verão.

Segundo o Instituto Nacional de Meteorologia (INMET) no período de 1991 a 2020 verificar-se, para a região noroeste do estado do Rio Grande do Sul, precipitações acumuladas anuais na faixa de 1800 mm a 2000 mm (dois primeiros tons de verdes na Figura 18). E para a estação climática do município de Cruz Alta evidencia que para o período histórico (1931-1960) a média anual acumulada é de 1725,10 mm, para o período de 1961-1990 é de 1630,60 mm, e para o período de 1991-2020 é de 1932,30 mm, sendo maior nos últimos 30 anos (Tabela 19). Nesses mesmos períodos pode-se observar na Figura 19 as médias mensais se diferenciam sendo a maior no mês de outubro com 245,2 mm para o período de 1991-2020; e a menor média mensal foi no mês de maio (108,1 mm) para o período de 1961-1990 (INMET, 2020).


A temperatura média do ar varia entre 13°C a 23°C (1961-2020), ocorrendo temperaturas mínimas de 9°C em julho (1961-2020) e máximas de 30°C em janeiro (1961-2020) (INMET, 2020).

Figura 18- Normais climatológicas do Brasil, precipitação acumulada anual (mm) no período de 1991 a 2020 registrado pelas estações climatológicas do Instituto Nacional de Meteorologia (INMET).



Fonte: INMET (<https://clima.inmet.gov.br/prec>)

Figura 19 – Comparativo das precipitações acumuladas (mm) entre os períodos históricos 1931-1960, 1961-1990 e 1991-2020 da Estação Climática de Cruz Alta do Instituto Nacional de Meteorologia – INMET.



Fonte: INMET (<https://clima.inmet.gov.br/GraficosClimatologicos/DF/83377>)

Tabela 6 – Precipitação acumulada mensal (mm) e média anual (mm) entre os períodos históricos 1931-1960, 1961-1990 e 1991-2020 da Estação Climática de Cruz Alta do Instituto Nacional de Meteorologia – INMET.

MESES	PRECIPITAÇÃO ACUMULADA (mm)			ESTAÇÃO DO ANO
	1931-1960	1961-1990	1991-2020	
Janeiro	148,1	119,7	154,6	Verão
Fevereiro	126,3	136,3	148,7	Verão
Março	123	126,5	138,2	Verão/Outono
Abril	154	119,5	154,9	Outono
Maio	153,6	108,1	148,8	Outono
Junho	167,8	116,3	159,5	Outono/Inverno
Julho	124	139,7	157,7	Inverno
Agosto	125,8	171	125,4	Inverno
Setembro	157,6	169,6	162,5	Inverno/Primavera
Outubro	185,6	144,5	245,9	Primavera
Novembro	119,8	124,6	156,6	Primavera
Dezembro	139,5	154,8	179,5	Primavera/Verão
Média anual	1725,10	1630,60	1932,30	

Fonte: Adaptado de INMET.

5.1.2 Análise e descrição dos dados das estações fluviométricas e pluviométricas da bacia Potiribu

O monitoramento dos dados utilizados nesta pesquisa, é realizado nas estações fluviométricas Andorinhas (Bacia do Potiribu), Cambará, Taboão, Alemão, Turcato e Donato que são compostas, cada estação, por uma régua linimétrica e um sensor de nível, que atualmente é da marca OTT- modelo Thalimedes com sensor de boia, exceto para a bacia do Donato, que possui sensor de nível é de pressão da marca Druck. Nas bacias Potiribu, Taboão, Turcato e Donato foram instalados um sensor óptico de turbidez da marca DTS-12, porém, esses sensores funcionam geralmente por um ano, por isso os dados dos turbidímetros não serão utilizados nesta pesquisa. Tanto os linigrafos, como os sensores de nível são conectados em *datalogger* para armazenamento dos dados, registrados a cada 10 minutos. Dezessete pluviógrafos foram instalados nas bacias (PVG-11, PVG-12, PVG-13, PVG-14, PVG-22, PVG-23, PVG-25, PVG-26, PVG-33, PVG-34, PVG-37, PVG-38, PVG-40, PVG-41, PVG-42, PVG-43, PVG-51), para o monitoramento das precipitações, também com registros a cada 10 minutos, embora, muitos deles tenham sido desativados por falha nos equipamentos.

Os dados monitorados nestas estações são nível d'água, vazão, turbidez (exceto para Cambará e Alemão), CSS e precipitação. São realizadas campanhas mensais para as medições de vazão e coleta de amostras de sedimentos em suspensão para posterior quantificação da CSS, e medição em eventos de cheia quando possível.

As variáveis vazão e CSS são medidas em conjunto. As medições de vazão nas seções de monitoramento foram realizadas com molinete hidrométrico, até a compra de um ADCP (2008), quando se passou a utilizar sempre esse equipamento. As amostragens de sedimentos em suspensão foram realizadas pelo método de integração na vertical por Igual Incremento de Largura, onde a velocidade de trânsito do equipamento ao descer e subir ao longo da vertical é constante em todas as verticais (EDWARD e GLYSSON, 1999). Para tal utilizou-se os equipamentos DH-48 e DH-59, dependendo do nível de água e da velocidade no momento do monitoramento. Após a coleta de sedimentos, as mesmas foram levadas para o laboratório de sedimentos do IPH-UFRGS para a determinação de CSS, através do método de Filtragem. Para ambas as medições (vazão e CSS) o método de medição

foi realizado a vau, quando o rio se encontrava com cota baixa o suficiente para o operador entrar com segurança dentro do rio, em quase todas as estações (menos nas de Andorinhas e Cambará), e quando o rio estava com cota alta, utilizou-se o barco nas estações de Andorinhas e eventualmente na de Cambará, e sistema teleférico nas estações Cambará e Turcato. Na estação fluviométrica do Alemão somente foi realizada medição à vau, pois não foram instalados o sistema teleférico e a ponte próxima a esta estação não é adequada por não ter apoio para a realização de medições.

5.1.3 Organização e consistência dos dados selecionados na pesquisa

Nas Tabelas 7 e 8 é apresentado um resumo dos dados observados das estações pluviométricas e fluviométricas utilizadas na pesquisa, com seus respectivos períodos e total de registros disponíveis.

Os dados que foram selecionados no estudo são: precipitação (P) dos 17 pluviôgrafos registrados nos períodos de 07/11/1989 até 13/02/2020 com intervalo de 3 horas; vazões (Q) obtidas nas estações fluviométricas nos períodos de 22/02/1991 a 15/06/2020, medidas *in loco* e também estimada pela curva-chave das estações, interpolados para o intervalo de três horas; CSS também obtidos nas estações fluviométricas nos períodos de 04/06/2013 a 13/02/2020 sendo amostras não sistemáticas (coletas mensais e alguns eventos de cheia); e PSS os quais foram calculados a partir da Q e da CSS.

Dentre os dados observados de Q, CSS e PSS pode-se verificar que os valores variam de 0,02 a 66,05m³/s, de 1,79 a 1520,70mg/L e de 4,55 x10⁻⁵kg/s a 6,56x10¹kg/s (Tabela 9). As concentrações (CSS) maiores foram nas bacias Turcato e Taboão devido às campanhas realizadas durante eventos extremos medidos, observando-se que as vazões monitoradas aumentam com o aumento das áreas de captação, exceto para o valor obtido para um evento extremo medido apenas na bacia do Turcato. Além desses eventos, com exceção da menor bacia, que é o Donato (1,1 km²), que apresentou CSS máximo de 346,66 mg/L, as demais bacias apresentam CSSs máximos entre 109,36 e 189,49 mg/L, que não são muito diferentes, sugerindo que a escala da bacia não influencia muito a ordem de magnitude dos valores de CSS para áreas de bacia entre 19 e 524 km² (Tabela 9).

Os dados de precipitação horária foram obtidos a partir da média aritmética dos registros de totais horários dos 17 pluviógrafos (PVG-11, PVG-12, PVG-13, PVG-14, PVG-22, PVG-23, PVG-25, PVG-26, PVG-31, PVG-33, PVG-34, PVG-37, PVG-40, PVG-41, PVG-42, PVG-43 e PVG-51) para o período de 1990 a 2020 (Tabela 7). Estas médias foram integradas para intervalos de três horas, constituindo as séries tri-horárias de precipitação. Esta estratégia foi adotada devido aos dados terem muitas lacunas.

Os dados de P e Q foram selecionados na escala temporal tri-horárias para ser compatível com a escala temporal dos dados de chuvas estimados pelo modelo climático regional para os dois cenários futuros, utilizados nesta pesquisa. No caso da série de Q somente foram utilizados os valores que são compatíveis com o mesmo período existente de medição de CSS. A produção de sedimentos em suspensão (PSS), que será a saída dos modelos, é obtida pelo produto da vazão pela respectiva concentração de sedimentos em suspensão (CSS).

Tabela 7 – Estações pluviométricas e dados de precipitação utilizados na pesquisa.

Nome	Coordenadas Geodésicas SIRGAS 2000		Período (horário)	Variáveis	Total de Registros	Responsável/Acesso
	Latitude	Longitude				
PVG_11*	S 28°25'16.621"	O 53°41'14.750"	11/12/1989 a 30/08/1996	Precipitação	39488	
PVG_12*	S 28°25'36.781"	O 53°40'36.949"	07/11/1989 a 13/12/1990	Precipitação	9072	
PVG_13*			20/05/1999 a 19/11/2016	Precipitação	66786	
PVG_14*	S 28°25'19.861"	O 53°40'13.909"	19/12/1990 a 01/07/1999	Precipitação	62371	
PVG_22*	S 28°24'3.901"	O 53°39'54.829"	09/11/1989 a 17/01/1996	Precipitação	28118	
PVG_23*	S 28°25'6.901"	O 53°39'15.949"	21/08/1989 a 09/05/2006	Precipitação	115758	
PVG_25*	S 28°26'1.621"	O 53°39'42.949"	27/05/1990 a 15/02/1996	Precipitação	20895	
PVG_26*	S 28°26'30.781"	O 53°41'41.030"	08/11/1989 a 15/05/1996	Precipitação	43707	
PVG_31*	S 28°28'25.621"	O 53°40'20.030"	25/08/1989 a 15/05/1996	Precipitação	35673	
PVG_33*	S 28°27'33.783"	O 53°35'1.787"	18/12/1990 a 29/09/1991	Precipitação	4863	IPH
PVG_34	S 28°27'00.41908"	O 53°37'09.29118"	16/02/2012 a 13/02/2020	Precipitação	148300	
PVG_37	S 28°27'24.25497"	O 53°43'17.82530"	16/08/2016 a 27/09/2019	Precipitação	108915	
PVG_40	S 28°28'53.93975"	O 53°36'23.74841"	10/09/2003 a 13/02/2020	Precipitação	102892	
PVG_41	S 28°26'21.42211"	O 53°38'18.97854"	15/09/2003 a 29/08/2007	Precipitação	8679	
PVG_42	S 28°25'03.02178"	O 53°43'37.99297"	10/09/2003 a 26/09/2019	Precipitação	40455	
PVG_43	S 28°25'16.49449"	O 53°41'24.50058"	10/09/2003 a 11/02/2020	Precipitação	97285	
PVG_51	S 28°23'38.81728"	O 53°41'36.89948"	30/08/1989 a 10/02/2020	Precipitação	122369	

*PVGs antigos e desativados

Fonte: A autora.

Tabela 8 – Estações fluviométricas e dados utilizados na pesquisa.

Nome	Município	Coordenadas Geodésicas SIRGAS 2000		Período	Variáveis	Total de Registros	Responsável/ Acesso
		Latitude	Longitude				
Andorinhas	Pejuçara/RS	S 28°24'48.79824"	O 53°48'44.10809"	01/03/2015 a 17/11/2020 (tri-horária)	Vazão	16248	IPH
				03/03/2015 a 11/02/2020 (não sistemática)*	CSS	35	
Cambará	Pejuçara/RS	S 28°27'19.79513"	O 53°45'05.31823"	16/10/2015 a 17/11/2020 (tri-horária)	Vazão	14599	IPH
				25/07/2016 a 21/01/2020 (não sistemática)*	CSS	24	
Taboão	Pejuçara/RS	S 28°26'24.07111"	O 53°44'30.46544"	10/01/2002 a 22/04/2019 (tri-horária)	Vazão	32680	IPH
				04/06/2013 a 12/02/2020 (não sistemática)*	CSS	82	
Turcato	Pejuçara/RS	S 28°26'18.23965"	O 53°40'59.43413"	22/02/1991 a 20/11/2020 (tri-horária)	Vazão	52303	IPH
				01/11/2014 a 12/02/2020 (não sistemática)*	CSS	41	
Alemão	Pejuçara/RS	S 28°27'47.33512"	O 53°38'36.09863"	22/01/2014 a 15/06/2020 (tri-horária)	Vazão	13432	IPH
				30/11/2014 a 13/02/2020 (não sistemática)*	CSS	30	
Donato	Pejuçara/RS	S 28°25'22.87753"	O 53°40'39.39192"	27/03/1991 a 10/02/2020 (tri-horária)	Vazão	65489	IPH
				05/06/2013 a 13/02/2020 (não sistemática)*	CSS	33	

*Coletas mensais (quando possível).

Fonte: A autora.

Tabela 9– Valores mínimos, máximos, médios e desvio padrão de vazão (Q), concentração de sedimentos em suspensão (CSS) e produção de sedimentos em suspensão (PSS) por bacias e total de registros de dados utilizados na pesquisa.

Dados observados	Bacias hidrográficas						Precipitação tri-horária (mm)			
	Potiribu (524,3km ²)	Cambará (356,1km ²)	Taboão (77,5km ²)	Alemão (19,3km ²)	Turcato (19,2km ²)	Donato (1,3km ²)	Mínima	Máxima	Média	Desvio padrão
Q _{mín} (m ³ /s)	4,63	4,14	0,22	0,22	0,15	0,02				
Q _{máx} (m ³ /s)	66,05	21,06	18,12	1,24	49,75	0,18				
Q _{méd} (m ³ /s)	17,04	9,23	7,27	0,59	9,46	0,05				
Desvio padrão (m ³ /s)	12,08	4,35	5,69	0,29	17,14	0,03				
Total de registros utilizados	35	24	82	30	41	33				
CSS _{mín} (mg/L)	14,11	7,98	5,38	4,70	6,99	1,79				
CSS _{máx} (mg/L)	189,49	109,36	1308,54	152,62	1520,70	346,66				
CSS _{méd} (mg/L)	54,84	34,51	199,89	33,79	288,87	34,13	0	104,37	0,52	2,28
Desvio padrão (mg/L)	39,01	22,87	261,45	30,47	507,89	64,97				
Total de registros utilizados	35	24	82	41	30	33				
PSS _{mín} (kg/s)	1,19E-01	3,57E-02	2,08E-03	1,47E-03	1,69E-03	4,55E-05				
PSS _{máx} (kg/s)	1,25E+01	2,30E+00	1,90E+01	1,65E-01	6,56E+01	3,30E-02				
PSS _{méd} (kg/s)	1,34E+00	3,88E-01	2,59E+00	2,61E-02	1,13E+01	2,55E-03				
Desvio padrão (kg/s)	2,26E+00	4,90E-01	3,96E+00	3,59E-02	2,21E+01	6,61E-03				
Total de registros utilizados	35	24	82	41	30	33				

Fonte: A autora.

5.2 ETAPA 2 – CENÁRIO ATUAL

Nesta etapa, demonstra-se como foram desenvolvidos os estudos de variáveis de entrada e os modelos de RNAs em escala temporal tri-horária para estimar a produção de sedimentos em suspensão. Ambos os modelos foram treinados, validados e verificados com séries observadas de chuvas dos pluviógrafos instalados nas bacias em estudo, CSS e vazão. Para a execução dos modelos deste trabalho foi utilizado o software Matlab® R2012a.

5.2.1 Modelos de RNAs para estimativa de PSS

Neste item descreve-se como foram desenvolvidos, treinados, validados e verificados os modelos de RNAs, bem como as variáveis de entrada testadas nestes modelos baseados em RNAs em escala temporal tri-horária para estimar a produção de sedimentos em suspensão.

5.2.1.1 Separação das amostras

No desenvolvimento dos modelos de RNAs para a estimativa da produção de sedimentos foram utilizados os dados de precipitação (P), CSS e vazão (Q). Unindo todos os dados de CSS e vazão medidos em todas as bacias (Potiribu, Cambará, Taboão, Turcato, Donato) obteve-se um total de 245 registros válidos possíveis de serem utilizados nos modelos.

A seleção para a separação das amostras foi limitada pela série de saída do modelo (PSS), que possui 245 registros sem falhas. Desse total, os registros foram separados em amostras com proporção de 40,8 % para treinamento, 30,6 % para verificação e 28,6 % para validação de forma a totalizar 100, 75 e 70, respectivamente (Tabela 10). Em cada conjunto de amostras tem-se valores representativos de todas as bacias. Por exemplo, na amostra para o treinamento (100 registros) tem-se 14, 10, 34, 16, 12 e 14 registros das bacias Potiribu, Cambará, Taboão, Turcato, Alemão e Donato, respectivamente, sendo que para cada bacia foram incluídos na amostra de treinamento os valores mínimos e máximos registrados, mantendo-se a mesma proporção para cada bacia (Tabela 10).

Tabela 10 – Separação de amostras para a execução dos modelos de RNAs.

Bacias/amostras	Nº de amostra				% de amostras		
	Total	Tr	Vr	VI	Tr	Vr	VI
Potitibu	35	14	11	10	5,7	4,5	4,1
Cambará	24	10	7	7	4,1	2,9	2,9
Taboão	82	34	25	23	13,9	10,2	9,4
Turcato	41	16	13	12	6,5	5,3	4,9
Alemão	30	12	9	9	4,9	3,7	3,7
Donato	33	14	10	9	5,7	4,1	3,7
Total		100	75	70	40,8	30,6	28,6
		245			100,0		

*Tr – amostra de treinamento; Vr – amostra da verificação; VI – amostra de validação.

Fonte: A autora.

5.2.1.2 Variáveis de entrada dos modelos

Primeiramente se realizou uma pesquisa dos dados de chuvas para localizar quais são as posições, nas séries de totais tri-horários, dos intervalos de três horas dentro dos quais ocorreram cada uma das medições de CSS. Com estas posições, são identificados os valores de precipitação nos intervalos, bem como os valores correspondentes dos sete intervalos de três horas anteriores a este, para cada medição. Ao final, resultaram oito séries de totais tri-horários de precipitação, sendo a primeira coincidente temporalmente (defasagem zero) com os intervalos dentro dos quais foram realizadas as medições de CSS, e as demais com defasagens crescentes em direção ao passado.

A média móvel Gama (FINCK; PEDROLLO, 2021) é utilizada para a integração das precipitações tri-horárias, com a finalidade principal de agrupar informações temporais, reduzindo o número de entradas. Este filtro temporal foi escolhido por sua capacidade de assumir formas que incluem o decaimento exponencial (MOORE, 1982), dependendo do ajuste, de forma que resulta quase sempre pelo menos igual a este em desempenho.

O ajuste da média móvel dos valores passados foi realizado pela procura dos parâmetros de forma, de escala e de posição (representado por um retardo temporal), que resultam na melhor correlação com a PSS. A PSS existe somente nos tempos correspondentes à realização de medições de sedimentos em suspensão, enquanto

que as precipitações são tri-horárias. Assim, para cada conjunto de parâmetros experimentado uma série completa de médias móveis é gerada, com a separação dos valores correspondente às medições, os quais são correlacionados às PSS. Os melhores coeficientes de correlação linear de Pearson determinam os parâmetros escolhidos.

Adicionalmente, foram experimentadas duas alternativas para o ajuste dos filtros Gama. A primeira contempla a hipótese de que estes possuam parâmetros iguais para toda a região, então todos os 245 registros correspondentes às medições são utilizados para o ajuste. Neste caso, a quantidade de dados utilizada constitui uma vantagem. A segunda alternativa consiste na hipótese de que cada bacia possua um mecanismo próprio para a ação das precipitações na produção dos sedimentos. Neste caso, a quantidade menor de registros, para o ajuste do filtro para cada bacia, seria compensada por uma descrição melhor dos processos.

As outras variáveis de entrada do modelo foram as áreas das bacias. Foram testadas todas as combinações com estas variáveis de entrada (Tabela 11), sendo posteriormente verificado posteriormente o melhor modelo para aplicações de cenários futuros.

Tabela 11 – Combinações das variáveis de entrada utilizada nos modelos de RNAs para estimar a PSS.

Modelos	Variáveis de Entrada	Variável de Saída
RNA_PSS_1	Área; MMGb; P0; P1; P2; P3; P4; P5; P6; P7	
RNA_PSS_2	Área; MMGb; P0; P1; P2; P3; P4; P5; P6	
RNA_PSS_3	Área; MMGb; P0; P1; P2; P3; P4; P5	
RNA_PSS_4	Área; MMGb; P0; P1; P2; P3; P4	
RNA_PSS_5	Área; MMGb; P0; P1; P2; P3	
RNA_PSS_6	Área; MMGb; P0; P1; P2	PSS
RNA_PSS_7	Área; MMGb; P0; P1	
RNA_PSS_8	Área; MMGb; P0	
RNA_PSS_9	Área; MMGb	
RNA_PSS_10	Área	
RNA_PSS_11	Área; MMGg; P0; P1; P2; P3; P4; P5; P6; P7	

*MMGb – Filtro individual por bacia gama; MMGg – Filtro regional gama; P0 – Precipitação tri-horária no intervalo zero de medição de CSS e Vazão; P1 - Precipitação tri-horária no intervalo anterior a P0 de medição de CSS e Vazão; P2 - Precipitação tri-horária no intervalo anterior a P1 de medição de CSS e Vazão; P3 - Precipitação tri-horária no intervalo anterior a P2 de medição de CSS e Vazão; P4 - Precipitação tri-horária no intervalo anterior a P3 de medição de CSS e Vazão; P5 - Precipitação tri-horária no intervalo anterior a P4 de medição de CSS e Vazão; P6 - Precipitação tri-horária no intervalo anterior a P5 de medição de CSS e Vazão; P7 - Precipitação tri-horária no intervalo anterior a P6 de medição de CSS e Vazão.

Fonte: A autora.

Continuação da Tabela 11 - Combinações das variáveis de entrada utilizada nos modelos de RNAs para estimar a PSS.

Modelos	Variáveis de Entrada	Variável de Saída
RNA_PSS_12	Área; MMGg; P0; P1; P2; P3; P4; P5; P6	
RNA_PSS_13	Área; MMGg; P0; P1; P2; P3; P4; P5	
RNA_PSS_14	Área; MMGg; P0; P1; P2; P3; P4	
RNA_PSS_15	Área; MMGg; P0; P1; P2; P3	
RNA_PSS_16	Área; MMGg; P0; P1; P2	
RNA_PSS_17	Área; MMGg; P0; P1	
RNA_PSS_18	Área; MMGg; P0	
RNA_PSS_19	Área; MMGg	
RNA_PSS_20	Área; P0; P1; P2; P3; P4; P5; P6; P7	
RNA_PSS_21	Área; P0; P1; P2; P3; P4; P5; P6	
RNA_PSS_22	Área; P0; P1; P2; P3; P4; P5	
RNA_PSS_23	Área; P0; P1; P2; P3; P4	
RNA_PSS_24	Área; P0; P1; P2; P3	
RNA_PSS_25	Área; P0; P1; P2	
RNA_PSS_26	Área; P0; P1	PSS
RNA_PSS_27	Área; P0	
RNA_PSS_28	MMGb	
RNA_PSS_29	MMGb; P0; P1; P2; P3; P4; P5; P6; P7	
RNA_PSS_30	MMGb; P0; P1; P2; P3; P4; P5; P6	
RNA_PSS_31	MMGb; P0; P1; P2; P3; P4; P5	
RNA_PSS_32	MMGb; P0; P1; P2; P3; P4	
RNA_PSS_33	MMGb; P0; P1; P2; P3	
RNA_PSS_34	MMGb; P0; P1; P2	
RNA_PSS_35	MMGb; P0; P1	
RNA_PSS_36	MMGb; P0	
RNA_PSS_37	MMGg	
RNA_PSS_38	MMGg; P0; P1; P2; P3; P4; P5; P6; P7	
RNA_PSS_39	MMGg; P0; P1; P2; P3; P4; P5; P6	
RNA_PSS_40	MMGg; P0; P1; P2; P3; P4; P5	

*MMGb – Filtro individual por bacia gama; MMGg – Filtro regional gama; P0 – Precipitação tri-horária no intervalo zero de medição de CSS e Vazão; P1 - Precipitação tri-horária no intervalo anterior a P0 de medição de CSS e Vazão; P2 - Precipitação tri-horária no intervalo anterior a P1 de medição de CSS e Vazão; P3 - Precipitação tri-horária no intervalo anterior a P2 de medição de CSS e Vazão; P4 - Precipitação tri-horária no intervalo anterior a P3 de medição de CSS e Vazão; P5 - Precipitação tri-horária no intervalo anterior a P4 de medição de CSS e Vazão; P6 - Precipitação tri-horária no intervalo anterior a P5 de medição de CSS e Vazão; P7 - Precipitação tri-horária no intervalo anterior a P6 de medição de CSS e Vazão.

Fonte: A autora.

Continuação da Tabela 11 - Combinações das variáveis de entrada utilizada nos modelos de RNAs para estimar a PSS.

Modelos	Variáveis de Entrada	Variável de Saída
RNA_PSS_41	MMGg; P0; P1; P2; P3; P4	
RNA_PSS_42	MMGg; P0; P1; P2; P3	
RNA_PSS_43	MMGg; P0; P1; P2	
RNA_PSS_44	MMGg; P0; P1	
RNA_PSS_45	MMGg; P0	
RNA_PSS_46	P0; P1; P2; P3; P4; P5; P6; P7	
RNA_PSS_47	P0; P1; P2; P3; P4; P5; P6	PSS
RNA_PSS_48	P0; P1; P2; P3; P4; P5	
RNA_PSS_49	P0; P1; P2; P3; P4	
RNA_PSS_50	P0; P1; P2; P3	
RNA_PSS_51	P0; P1; P2	
RNA_PSS_52	P0; P1	
RNA_PSS_53	P0	

*MMGb – Filtro individual por bacia gama; MMGg – Filtro regional gama; P0 – Precipitação tri-horária no intervalo zero de medição de CSS e Vazão; P1 - Precipitação tri-horária no intervalo anterior a P0 de medição de CSS e Vazão; P2 - Precipitação tri-horária no intervalo anterior a P1 de medição de CSS e Vazão; P3 - Precipitação tri-horária no intervalo anterior a P2 de medição de CSS e Vazão; P4 - Precipitação tri-horária no intervalo anterior a P3 de medição de CSS e Vazão; P5 - Precipitação tri-horária no intervalo anterior a P4 de medição de CSS e Vazão; P6 - Precipitação tri-horária no intervalo anterior a P5 de medição de CSS e Vazão; P7 - Precipitação tri-horária no intervalo anterior a P6 de medição de CSS e Vazão.

Fonte: A autora.

5.2.1.3 Desenvolvimento e treinamento dos modelos

Os modelos desenvolvidos são do tipo perceptron de múltiplas camadas, com arquitetura de três camadas constituindo uma camada de entrada, uma camada intermediária e uma camada de saída. Esta escolha foi realizada tendo por base no teorema da existência, de Hecht-Nielsen (1987). Este teorema estabelece que uma rede neural com uma única camada interna é capaz de mapear qualquer relação numérica contínua com $2n + 1$ neurônios na camada interna, sendo n o número de variáveis. Portanto, o número de neurônios deverá satisfazer, aproximadamente, esta relação.

A função de ativação da RNA foi realizada pela sigmoide unipolar (Eq. 15).

$$f(x) = \frac{1}{(1 + \exp(-x))} \quad (9)$$

Onde: f é a função sigmoide unipolar e x é a variável de entrada.

O método de treinamento adotado foi o de validação cruzada, o qual requer a divisão dos dados em três amostras, de treinamento, de verificação e de validação. Para que a amostragem de treinamento seja mais representativa, foram incluídos nesta os registros com dados extremos (mínimos e máximos) de cada variável (entrada ou saída). Para que seja mais provavelmente completado o treinamento, sendo interrompido, se for o caso, no limiar de sobreajustamento (HECHT-NIELSEN, 1990), foi adotado um número máximo de 100.000 ciclos. Para contornar a variabilidade resultante da aleatoriedade inicial dos pesos sinápticos no método retropropagativo (RUMELHART *et al.*, 1986), foram efetuadas 30 repetições iniciais do treinamento, com adoção da RNA resultante com o melhor desempenho na validação. Esta técnica requer um número expressivo de registros, para separar as amostras em 50% para Treinamento, 25% para Validação e 25% para Verificação (HECHT-NIELSEN, 1990), sendo o mínimo de 30 registros para a amostra de treinamento (SARI; CASTRO; PEDROLLO, 2017). Para contornar este problema foi realizada a união de todos os dados das bacias Potiribu, Cambará, Taboão, Alemão, Turcato e Donato, de forma a obter modelos regionais.

5.2.2 Estatísticas de desempenho dos modelos de RNAs

Para as análises e a escolha dos melhores modelos, os desempenhos foram verificados a partir das estatísticas aplicadas, comparando-se os resultados estimados com os observados. Para isso, utilizou-se NS (NASH; SUTCLIFFE, 1970), Pbias e Mae. A interpretação para a verificação do melhor modelo considerou as diretrizes de classificação propostas por Moriasi *et al.* (2015) (ver item 4.7). Além disso, foram realizadas análises visuais dos gráficos, *PSS observado X PSS estimado*, para os diferentes modelos. Após, aplicou-se o melhor modelo de RNA escolhido para a estimativa de PSS e com este modelo será estimado o PSS para os dois cenários climáticos futuros. Para tanto, foram utilizadas as chuvas tri-horárias correspondentes ao respectivo modelo climático regional, após a devida correção do viés para a região de estudo.

5.3 ETAPA 3: CENÁRIOS FUTUROS

Nesta etapa apresenta-se o modelo climático escolhido para o estudo, descrevendo-se como foi realizada a obtenção dos dados desse modelo e correção de viés. Foram realizadas as simulações do modelo de RNA escolhido para estimar a produção de sedimentos em suspensão nos dois cenários de mudanças climáticas projetadas para o futuro, sendo o RCP 4.5, o mais otimista e, RCP 8.5, o mais pessimista. E por fim, realizou-se a análise do comportamento sazonal das séries temporais e a comparação das projeções dos cenários futuros com o período observado.

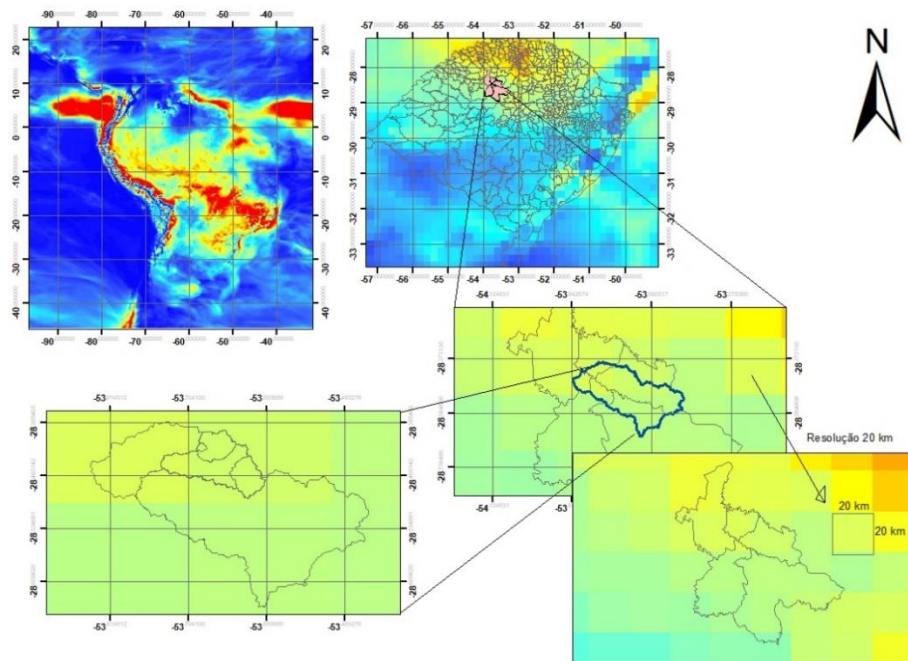
5.3.1 Modelo climático regional (MCR) e obtenção dos dados simulados

As séries de precipitação simuladas pelo modelo climático regional Eta-HadGEM2-ES CPTEC/INPE foram obtidas a partir da plataforma PROJETA para os cenários climáticos histórico e futuro (RCP4.5 e RCP8.5).

Estes dados hidrológicos são simulados pelo modelo climatológico regional Eta-HadGEM2-ES CPTEC/INPE, que é um modelo atmosférico regional de última geração, regional que utiliza a coordenada Eta e os dados do modelo global HadGEM2-ES como condições de contorno (COLLINS *et al.*, 2011; MARTIN *et al.*, 2011). Este modelo tem resolução espacial de 20km x 20km, ou seja, cada pixel contém uma área de 400 km², isso significa que os dados simulados pelo modelo pega quase todo a bacia maior que tem uma área de 524,3 km² (Potiribu), sendo utilizado quase 2 pixels das simulações dos dados de precipitação desse modelo. Assim, podendo ser subestimado os valores de precipitação nas bacias em estudo principalmente para as áreas menores que utilizam apenas um pixel de detalhamento para a projeção desses dados (Figura 21). Para contornar isso foi realizado a correção de viés que será abordado no próximo item.

Nesta plataforma foram baixados os dados no formato JSON (JavaScript Object Notation) que é um formato aberto usado como alternativa ao XML para a transferência de dados estruturados entre um servidor de Web e uma aplicação Web, sendo escolhido o cenário (histórico, RCP 4.5, RCP 8.5) e modelo climático (HadGEM2-ES-20km), com dados de frequência (tri-horária), variável (precipitação total), e coordenadas (bacia potiribu).

Figura 20 - Exemplificação da projeção da imagem do modelo climático regional Eta CPTEC/INPE com resolução espacial de 20 Km.



Fonte: A autora.

Os dados de precipitação baixados e seus respectivos cenários e períodos são apresentados na Tabela 12.

Tabela 12 – Dados de precipitação baixados da plataforma PROJETA INPE.

VARIÁVEL	SIGLA	MODELO CLIMÁTICO	CENÁRIO	TEMPO
Precipitação	PREC	HadGEM2-ES_continental-20km	Histórico (1960-2005)	
			RCP4.5 (2005-2099)	Tri-horário
			RCP8.5 (2006-2099)	

Fonte: A autora.

5.3.2 Correção de viés dos dados do modelo climático regional Eta-HadGEM2-ES CPTEC/INPE

Conforme destacado anteriormente quando as pesquisas envolvem mudanças climáticas e a utilização de dados simulados por modelos climáticos, é recomendada a aplicação de correção do viés. Por isso, neste estudo, foi realizada a correção do viés tendo como base os métodos que envolvem distribuição de probabilidades

acumuladas como as propostas por Li, Sheffield e Wood (2010), Switanek *et al.* (2017) e Lehner; Nadeem e Formayer (2021).

Para a correção do viés foi utilizada a série observada de precipitação (1990 a 2005) que corresponde ao mesmo período da série de precipitação histórica simulada pelo modelo climático (1990 a 2005).

Primeiro foi corrigido o viés do período histórico para ser verificada a distribuição de frequência acumulada e após foi realizado o mesmo método para corrigir as séries de precipitações dos cenários climáticos RCP 4.5 e RCP 8.5, ambos para os períodos de 2006 a 2099.

O método proposto neste estudo foi o de distribuição de frequência empírica de Lehner modificado. Este método consiste em transferir a escala dos dados de precipitação simulados por modelos climáticos regionais para os dados observados dessa região de estudo (bacia do Potiribu). Para isso a base de cálculo pode ser descrita pela equação 16:

$$P_{mp_oh} = P_{mp} * \frac{F_{inv_{oh}}(F_{mp}(P_{mp}))}{F_{in_mh}(F_{mp}(P_{mp}))} \quad (10)$$

Onde: *o* são os dados observados; *m* é o modelo; *h* é o período histórico; *p* é a projeção futura; F_{in} é a função inversa de F ; P_{mp_oh} são as precipitações do modelo futuro, convertidas para a escala dos dados observados históricos; P_{mp} são as precipitações do modelo em projeções futuras (cenários RCP 4.5 ou RCP8.5); e F_{mp} é a função de distribuição acumulada F do modelo climático com as projeções.

Para a obtenção do F , Lehner; Nadeem e Formayer (2021) cria uma função de F100 (quantis 0; 0,01; 1) de cada F para relacionar em uma tabela, onde estabelece uma divisão ou um produto de 100 números por 100 números e deste conjunto é retirado um valor para ser inserido na equação 10 e ainda faz uma interpolação interna. Porém, este método depende, para frequências intermediárias, do uso de interpolações, estando por isso sujeito a imprecisões. Em razão disso, propôs-se, neste trabalho, gerar a função F e os quantis utilizando toda a série de dados (histórico, observados, cenários futuros) para cada valor da série, ou seja, um número por vez de cada série para calcular as frequências é aplicado na equação 10, fazendo isso para todos os valores de cada série. Quando os valores do quociente

$(F_{in_mh}(F_{mp}(P_{mp})))$) resultam no zero fica inviável a utilização da equação 10, assim foi adotado “zero” para o quantil neste período. Estas transformações, para as séries de dados tri-horários utilizadas (46477 valores para a série de dados produzida pelo modelo climático no período histórico e 274417 valores para a série de dados produzidos no período de 2006 a 2099) foram realizadas em cerca de 20 minutos para cada cenário analisado, o que não é muito tempo, considerando que a operação foi realizada para cada valor individual.

5.3.3 Aplicação dos modelos para os cenários climáticos (observado e cenários futuros RCP 4.5 e RCP 8.5)

A aplicação do modelo RNA deu-se a partir da escolha do melhor modelo, sendo esse modelo simulado para os cenários climáticos observado (1990 a 2020), RCP 4.5 (otimista) e RCP 8.5 (pessimista) para verificar a influência das mudanças climáticas na produção de sedimentos em suspensão no futuro (2021 a 2099) e comparar com o cenário atual para cada uma das bacias em estudo. Com o objetivo de melhorar a visualização gráfica das séries tri-horárias simuladas e também para a comparação entre os cenários, os resultados de precipitação e PSS para as projeções futuras foram divididos em: o “cenário futuro próximo” que corresponde ao período de 2021 a 2051, compreendendo apenas 30 anos após o período observado (1990 a 2020) e o “cenário futuro distante” que corresponde ao período de 2052 a 2082, compreendendo 30 anos após o futuro próximo, sendo 60 anos após o período observado. Assim não sendo considerado nas análises o período após o ano de 2082.

5.3.4 Análise do comportamento sazonal das séries temporais simuladas pelo modelo RNA nos cenários climáticos

Para analisar a presença de comportamento sazonal das séries geradas de PSS nas diferentes bacias, tanto do período “atual”, bem como dos futuros simulados, foram utilizadas ferramentas tradicionais para a análise de séries temporais, a saber, análise dos gráficos da autocorrelação (FAC), autocorrelação parcial (FACP) e do periodograma das séries temporais de cada bacia (MORETTIN; TOLOI, 2004). Porém, primeiramente foi analisado o comportamento da série observada verificando a sua

estacionariedade a partir de uma inspeção visual do gráfico das séries temporais, e testando cada série quanto à sua estacionariedade utilizando-se o teste de Phillips-Perron (PHILLIPS; PERRON, 1988), cuja hipótese nula pode ser interpretada como “a série NÃO é estacionária”.

O Teste de Phillips-Perron é um teste de raiz unitária utilizado para testar se uma dada série temporal é estacionária ou não. A hipótese nula é formulada em termos da regressão da série temporal Y_t em relação ao seu passado imediato, Y_{t-1} , isto é, (Eq. 11).

$$Y_t = \alpha + \beta Y_{t-1} + \epsilon_t \quad (11)$$

Onde: ϵ_t é um termo de erro. Nesse contexto a hipótese nula se torna $H_0: \beta = 1$, significando que série em questão possui uma raiz unitária, sendo, portanto, não estacionária. A rejeição da hipótese nula é a evidência de que a série temporal sendo testada é estacionária (MORETTIN; TOLOI, 2006; PHILLIPS; PERRON; 1998).

O Periodograma é um estimador para a densidade espectral de uma série temporal estacionária, baseado na transformada rápida de Fourier da série. Se Y_1, \dots, Y_n é uma amostra de tamanho n uma série temporal, definimos o periodograma da série calculado na frequência $\lambda \in \mathbb{R}$ como sendo (Eq. 12).

$$I_n(\lambda) = \frac{1}{2\pi n} \left| \sum_{k=1}^n Y_k e^{-i\lambda k} \right|^2 \quad (12)$$

Onde: i denota o número imaginário. Embora seja definido para todas as frequências $\lambda \in \mathbb{R}$, na prática o periodograma é calculado apenas nas frequências de Fourier, $\lambda_j = 2\pi j/n$, para $j \in \{1, \dots, n\}$, sendo que frequências que apresentam valores elevados do periodograma (picos) são interpretadas como frequências de interesse. O periodograma é muito utilizado em análise de séries temporais para a detecção de sazonalidades (determinísticas e estocásticas) e na determinação do seu período (MORETTIN; TOLOI, 2006).

A Função de autocorrelação parcial: Se $\{Y_t\}_{\{t \in \mathbb{Z}\}}$ é uma série temporal estacionária, a autocorrelação parcial entre Y_t e Y_{t+h} , para $h > 0$, é a correlação entre

Y_t e Y_{t+h} retirada a influência das variáveis intermediárias $Y_{t+1}, \dots, Y_{t+h-1}$. O cálculo é feito através das equações de Yule-Walker (MORETTIN; TOLOI, 2006).

A função de autocorrelação e autocorrelação parcial são utilizadas em conjunto para determinar a estrutura de dependência de uma série temporal. A presença de sazonalidades é detectada pela repetição/oscilação periódica da função de autocorrelação.

6 RESULTADOS E DISCUSSÃO

Neste item são apresentados os resultados da pesquisa na seguinte sequência:

1. Análise e escolha do melhor modelo de PSS a partir das estatísticas de desempenho dos modelos testados com diferentes entradas.
2. Os resultados da PSS para os diferentes cenários climáticos simulados pelo modelo escolhido;
3. Análise do comportamento sazonal das séries temporais simuladas pelo modelo RNA nos cenários climáticos;
4. Comparação das projeções dos cenários futuros com o período observado.

6.1 ANÁLISE E ESCOLHA DO MELHOR MODELO DE PRODUÇÃO DE SEDIMENTOS EM SUSPENSÃO

Um aspecto importante nesta etapa é a determinação da arquitetura dos modelos. A variável de saída é a PSS, e as variáveis de entrada dependem de cada pesquisa realizada, uma vez que existem diversas combinações a serem testadas (precipitações de seis intervalos de três horas, uma média móvel de precipitações tri-horárias antecedentes e área de cada bacia), para a escolha do modelo mais eficiente. O número de neurônios internos adotado foi 17, considerando o número de entradas da situação mais abrangente esperada ($n=8$), e a fórmula apresentada pelo teorema de Hecht-Nielsen (1987), considerando que se trata de uma aproximação bastante utilizada.

Foram treinados 53 modelos no total, com diferentes combinações de entradas, sendo Área, MMGb (filtro gama individual por bacia com dados de chuvas), MMGg (filtro gama regional com dados de chuvas), chuvas tri-horárias antecedentes (P0, P1, P2, P3, P4, P5, P6, P7) como pode ser observado na Tabela 14.

Para a análise do desempenho foram analisados os valores das estatísticas, conforme a classificação de Moriasi *et al.* (2015), sendo observado que a maioria dos modelos resultaram em valores de NS > 0,8 tanto para as amostras de treinamento quanto para as amostras de verificação, classificados como “MUITO BOM”. Apenas os modelos RNA_PSS_10, 27 e 53 resultaram em valores de NS < 0,45, sendo classificados como “NÃO SATISFATÓRIOS”. Estes modelos apresentam como dados

de entrada somente a área, a área da bacia e a chuva (P0) e somente chuva (P0), respectivamente. Porém, para a busca do melhor modelo não se pode limitar aos resultados somente de NS, pois outras estatísticas também são importantes para esta análise. Assim, foram verificados os valores de Pbias. Com essa análise foram selecionados os melhores modelos apresentando um total de 51 modelos com Pbias $\leq \pm 10$ para as amostras de treinamento e 25 modelos para as amostras de verificação, e conforme a classificação de Moriasi *et al.* (2015), com desempenho considerado “MUITO BOM”.

Tabela 13 - Resultados das estatísticas dos Modelos de redes neurais artificiais para estimativa de PSS.

Modelos	Variáveis de Entrada	Desempenho (Tr)			Desempenho (Vr)		
		NS	Pbias	Mea (kg/s)	NS	Pbias	Mea (kg/s)
RNA_PSS_1	Área; MMGb; P0; P1; P2; P3; P4; P5; P6; P7	0,953	-7,07	1278	0,941	-22,5	781,3
RNA_PSS_2	Área; MMGb; P0; P1; P2; P3; P4; P5; P6	0,95	-8,84	1338	0,941	-25,4	791,9
RNA_PSS_3	Área; MMGb; P0; P1; P2; P3; P4; P5	0,954	-8,7	713,1	0,959	-7,96	742,9
RNA_PSS_4	Área; MMGb; P0; P1; P2; P3; P4	0,95	7,44	1206	0,921	-6,38	998,7
RNA_PSS_5	Área; MMGb; P0; P1; P2; P3	0,973	-0,686	975,8	0,95	-16,6	894,1
RNA_PSS_6	Área; MMGb; P0; P1; P2	0,886	-1,36	1970	0,939	6	888,5
RNA_PSS_7	Área; MMGb; P0; P1	0,909	0,27	1812	0,914	14,6	944,2
RNA_PSS_8	Área; MMGb; P0	0,947	-3,08	1388	0,947	1,39	914
RNA_PSS_9	Área; MMGb	0,875	-0,682	1793	0,904	13,9	865,1
RNA_PSS_10	Área	-0,014	45,1	5229	0,0085	-12,5	3262
RNA_PSS_11	Área; MMGg; P0; P1; P2; P3; P4; P5; P6; P7	0,931	5,26	1430	0,949	-11,6	772
RNA_PSS_12	Área; MMGg; P0; P1; P2; P3; P4; P5; P6	0,933	3,02	1398	0,94	-17,1	849,5
RNA_PSS_13	Área; MMGg; P0; P1; P2; P3; P4; P5	0,933	5,03	1405	0,959	-7,96	742,9
RNA_PSS_14	Área; MMGg; P0; P1; P2; P3; P4	0,925	7,32	1484	0,91	-13,6	1135
RNA_PSS_15	Área; MMGg; P0; P1; P2; P3	0,926	8,03	1458	0,936	-1,65	935,9
RNA_PSS_16	Área; MMGg; P0; P1; P2	0,951	-0,956	1358	0,948	-32,1	1038
RNA_PSS_17	Área; MMGg; P0; P1	0,947	-1,3	1442	0,942	-29,6	1101

*Pintados em cinza valores de NS e Pbias com desempenho "Muito Bom" pela classificação de Moriasi et al. (2015).

*Em negrito o melhor modelo selecionado.

*Vt – série de treinamento do modelo RNA.

*Vr – série de verificação do modelo RNA.

Fonte: A autora.

Continuação da tabela 12 - Resultados das estatísticas dos Modelos de redes neurais artificiais para estimativa de PSS.

Modelos	Variáveis de Entrada	Desempenho (Tr)			Desempenho (Vr)		
		NS	Pbias	Mea (kg/s)	NS	Pbias	Mea (kg/s)
RNA_PSS_18	Área; MMGg; P0	0,95	-3,9	1455	0,957	-26,7	1061
RNA_PSS_19	Área; MMGg	0,881	3,48	1914	0,941	-1,01	725,8
RNA_PSS_20	Área; P0; P1; P2; P3; P4; P5; P6; P7	0,926	5,44	1449	0,961	-4,24	763,2
RNA_PSS_21	Área; P0; P1; P2; P3; P4; P5; P6	0,926	5,63	1440	0,963	-2,91	723,8
RNA_PSS_22	Área; P0; P1; P2; P3; P4; P5	0,925	4,54	1490	0,96	-4,58	749,9
RNA_PSS_23	Área; P0; P1; P2; P3; P4	0,929	7,51	1495	0,873	-22,5	1196
RNA_PSS_24	Área; P0; P1; P2; P3	0,925	4,63	1530	0,95	4,29	884,1
RNA_PSS_25	Área; P0; P1; P2	0,949	-4,29	1626	0,954	-15,8	1254
RNA_PSS_26	Área; P0; P1	0,934	-1,93	1771	0,813	-3,7	1666
RNA_PSS_27	Área; P0	0,164	4,34	5482	0,042	-54,2	3765
RNA_PSS_28	MMGb	0,911	0,401	1638	0,941	18,5	780,7
RNA_PSS_29	MMGb; P0; P1; P2; P3; P4; P5; P6; P7	0,948	0,145	1356	0,943	-10,7	819,1
RNA_PSS_30	MMGb; P0; P1; P2; P3; P4; P5; P6	0,947	-0,054	1367	0,95	-10,2	775,7
RNA_PSS_31	MMGb; P0; P1; P2; P3; P4; P5	0,945	-1,47	1411	0,953	-7,26	759,1
RNA_PSS_32	MMGb; P0; P1; P2; P3; P4	0,95	7,21	1209	0,925	-5,99	978,6
RNA_PSS_33	MMGb; P0; P1; P2; P3	0,938	1,18	1401	0,937	-1,35	923,5
RNA_PSS_34	MMGb; P0; P1; P2	0,875	1,48	1943	0,936	6,1	750,5
RNA_PSS_35	MMGb; P0; P1	0,968	-0,704	1220	0,944	-0,67	904,5

*Pintados em cinza valores de NS e Pbias com desempenho "Muito Bom" pela classificação de Moriasi et al. (2015).

*Em negrito o melhor modelo selecionado.

*Vt – série de treinamento do modelo RNA.

*Vr – série de verificação do modelo RNA.

Fonte: A autora.

Continuação da tabela 12 - Resultados das estatísticas dos Modelos de redes neurais artificiais para estimativa de PSS.

Modelos	Variáveis de Entrada	Desempenho (Tr)			Desempenho (Vr)		
		NS	Pbias	Mea (kg/s)	NS	Pbias	Mea (kg/s)
RNA_PSS_36	MMGb; P0	0,936	1,4	1414	0,947	12,2	775,9
RNA_PSS_37	MMGg	0,875	5,53	1999	0,928	-0,51	833,5
RNA_PSS_38	MMGg; P0; P1; P2; P3; P4; P5; P6; P7	0,927	6,75	1496	0,93	-12,1	932,2
RNA_PSS_39	MMGg; P0; P1; P2; P3; P4; P5; P6	0,928	7,45	1483	0,942	-8,78	870
RNA_PSS_40	MMGg; P0; P1; P2; P3; P4; P5	0,928	7,77	1481	0,957	-3,41	793,3
RNA_PSS_41	MMGg; P0; P1; P2; P3; P4	0,918	9,34	1523	0,903	-9,62	1142
RNA_PSS_42	MMGg; P0; P1; P2; P3	0,929	7,7	1431	0,939	-0,7	887,4
RNA_PSS_43	MMGg; P0; P1; P2	0,946	-3,01	1546	0,946	-37,2	1228
RNA_PSS_44	MMGg; P0; P1	0,941	-1,75	1602	0,941	-32,3	1240
RNA_PSS_45	MMGg; P0	0,931	-1,22	1617	0,963	-20,9	1010
RNA_PSS_46	P0; P1; P2; P3; P4; P5; P6; P7	0,923	3,81	1532	0,956	-9,5	788,5
RNA_PSS_47	P0; P1; P2; P3; P4; P5; P6	0,922	3,6	1536	0,949	-12,3	848
RNA_PSS_48	P0; P1; P2; P3; P4; P5	0,923	3,89	1506	0,957	-7,22	763,9
RNA_PSS_49	P0; P1; P2; P3; P4	0,933	5,94	1394	0,876	-23,6	1189
RNA_PSS_50	P0; P1; P2; P3	0,923	5,08	1522	0,952	5,46	858,5
RNA_PSS_51	P0; P1; P2	0,946	-4,32	1708	0,955	-20,2	1284
RNA_PSS_52	P0; P1	0,931	-0,911	1862	0,818	-3,66	1701
RNA_PSS_53	P0	0,154	12,7	5252	0,035	-42,1	3596

*Pintados em cinza valores de NS e Pbias com desempenho "Muito Bom" pela classificação de Moriasi et al. (2015).

*Em negrito o melhor modelo selecionado.

*Vt – série de treinamento do modelo RNA.

*Vr – série de verificação do modelo RNA.

Fonte: A autora.

Nas Figuras 21 a 32 estão apresentadas a PSS observada e simulada em relação à reta de ajuste ideal (Figura 21a, Figura 22a, Figura 23a, Figura 24a, Figura 25a, Figura 26a, Figura 27a, Figura 28a, Figura 29a, Figura 30a, Figura 31a e Figura 32a); o erro verificado entre os valores calculados e observados de PSS (Figura 21b, Figura 22b, Figura 23b, Figura 24b, Figura 25b, Figura 26b, Figura 27b, Figura 28b, Figura 29b, Figura 30b, Figura 31b e Figura 32b) e; o comportamento dos valores de PSS observado e simulado, considerando os processos de treinamento (Figura 21c, Figura 22c, Figura 23c, Figura 24c, Figura 25c, Figura 26c, Figura 27c, Figura 28c, Figura 29c, Figura 30c, Figura 31c e Figura 32c) e de verificação (Figura 21d, Figura 22d, Figura 23d, Figura 24d, Figura 25d, Figura 26d, Figura 27d, Figura 28d, Figura 29d, Figura 30d, Figura 31d e Figura 32d) dos modelos RNA_PSS_1, 9, 10, 11, 19, 20, 21, 27, 28, 37, 46 e 53.

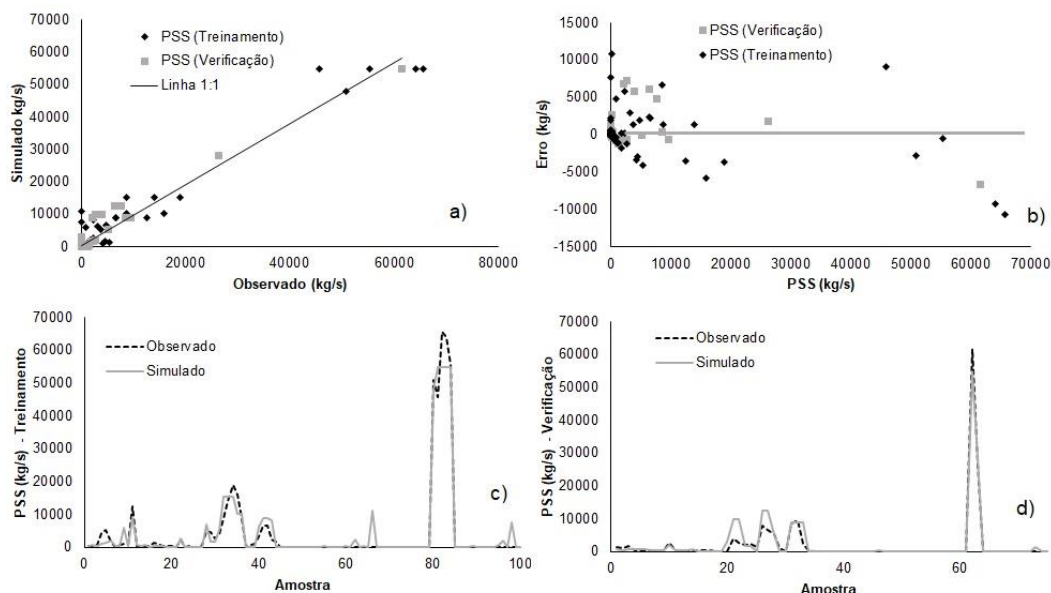
Geralmente, os modelos de RNAs desenvolvidos mostraram-se capazes de representar a variação do comportamento da PSS ao longo dos eventos, para cada uma das partes da subdivisão da amostra total (treinamento e verificação).

Entretanto, houve alguns problemas na representação dos picos de PSS monitorados nas bacias, os quais foram, muitas vezes, subestimados pelo modelo tanto na etapa do treinamento quanto na verificação (Figura 21c,d; Figura 22c,d; Figura 24c,d; Figura 25c,d; Figura 26c,d; Figura 27c,d; Figura 29c,d; Figura 30c,d; Figura 31c,d; e Figura 32c,d).

Analisando-se os erros máximos e mínimos registrados entre os valores de PSS observados e simulados para os processos de treinamento e verificação, observou-se que há um acúmulo de pontos próximos ao zero na linha de erro principalmente nos valores menores de PSS e percebe-se alguns pontos bem distantes do zero quando os valores de PSS aumentam (Figura 21b; Figura 22b; Figura 24b; Figura 25b; Figura 26b; Figura 27b; Figura 29b; Figura 30b; Figura 31b; e Figura 32b). Isso demonstra que o modelo não consegue reproduzir valores extremos de PSS sendo subestimado os picos. Considerando o Mea o menor valor obtido foi no modelo RNA_PSS_21 que teve um valor de 723,8 kg/s na verificação, condizendo com aquilo que foi verificado para as melhores relações de ajuste entre dados observados e simulados (Figura 27b). Este modelo entre os outros foi o que melhor representou a PSS e assim foi o escolhido para as simulações dos cenários climáticos futuros (Figura 27).

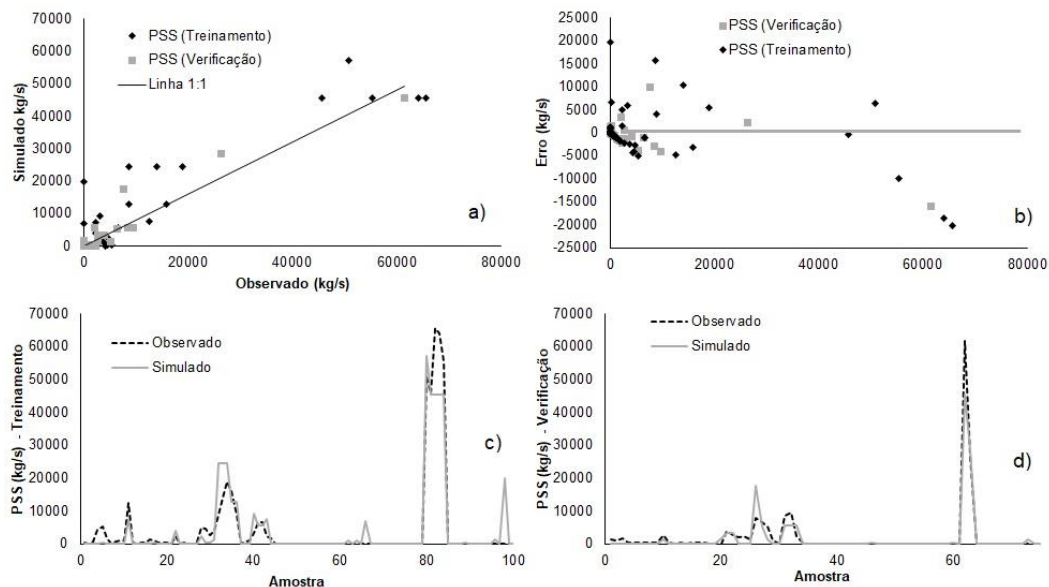
Já para os modelos com entradas somente área, área e chuva (P0) e somente chuva (P0) (Modelos: RNA_PSS_10, 27 e 53, respectivamente) observa-se que os valores de erro se afastam do zero à medida que a PSS vai aumentando (Figura 23, Figura 28 e Figura 32), não conseguindo reproduzir nenhum dos picos de PSS ao longo dos eventos (Figura 23c,d; Figura 28c,d e Figura 32c,d). Estes modelos tiveram um Mea de 5229kg/s (Treinamento), 3262kg/s (Verificação); 5252kg/s (Treinamento), 3596kg/s (Verificação); e 5482kg/s (Treinamento), 3765kg/s (Verificação) não obtendo um bom desempenho nestes modelos.

Figura 21 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_1.



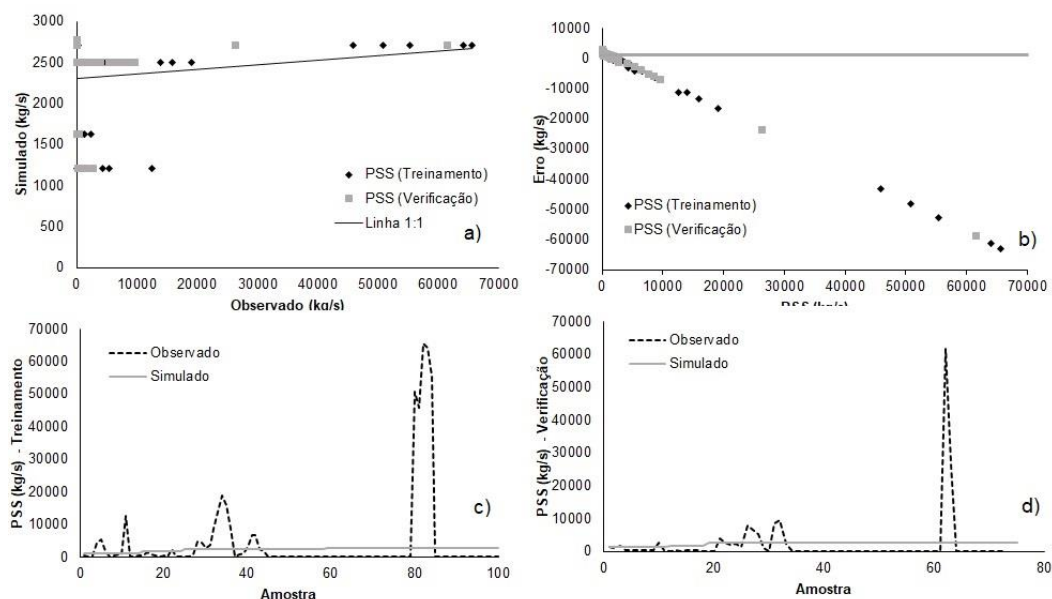
Fonte: A autora.

Figura 22 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_9.



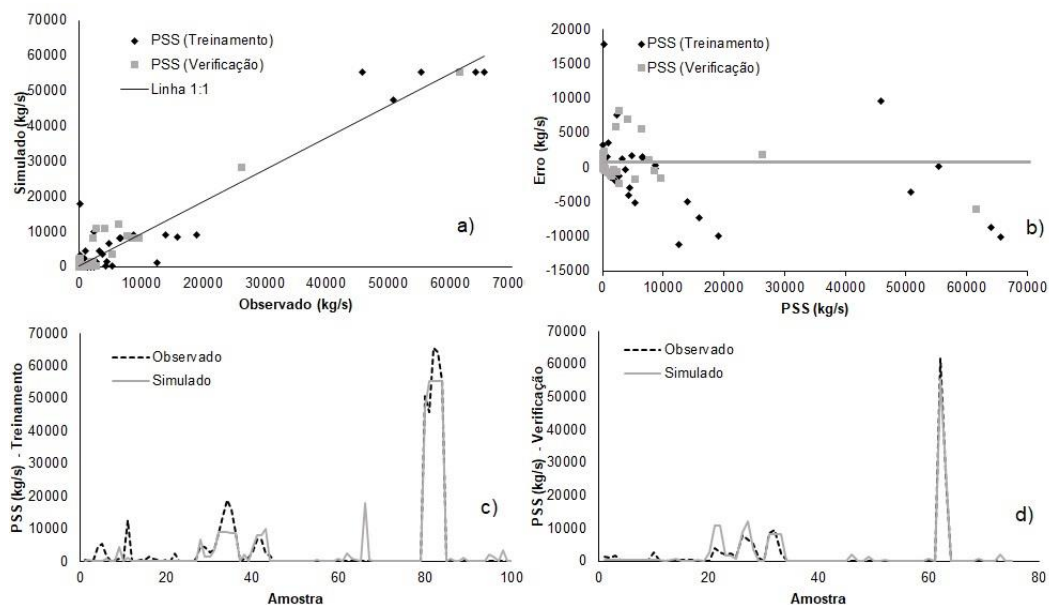
Fonte: A autora.

Figura 23 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_10.



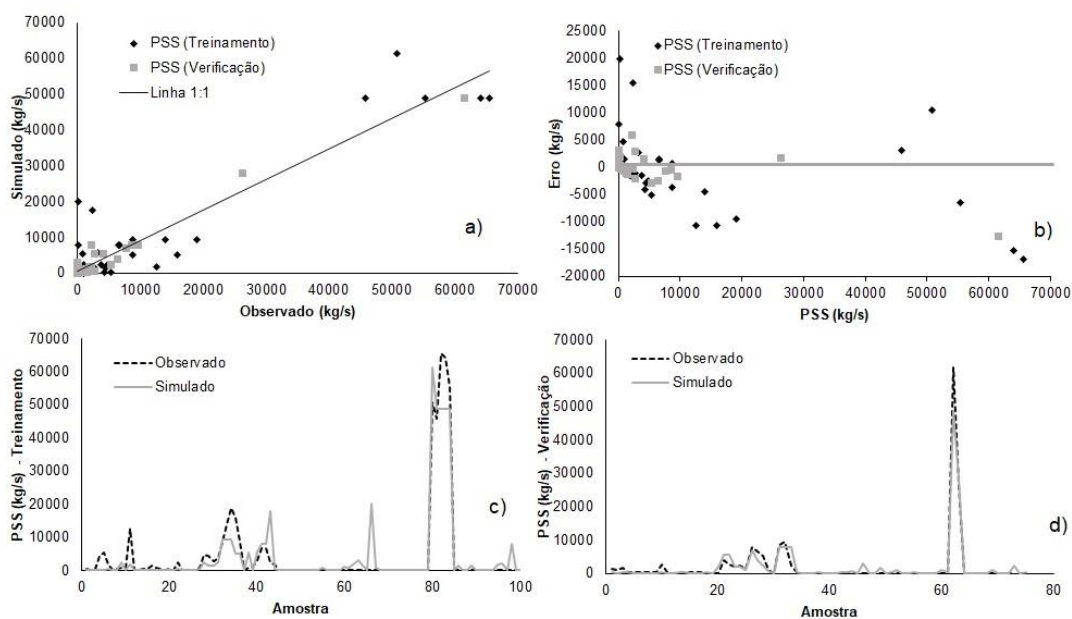
Fonte: A autora.

Figura 24 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_11.



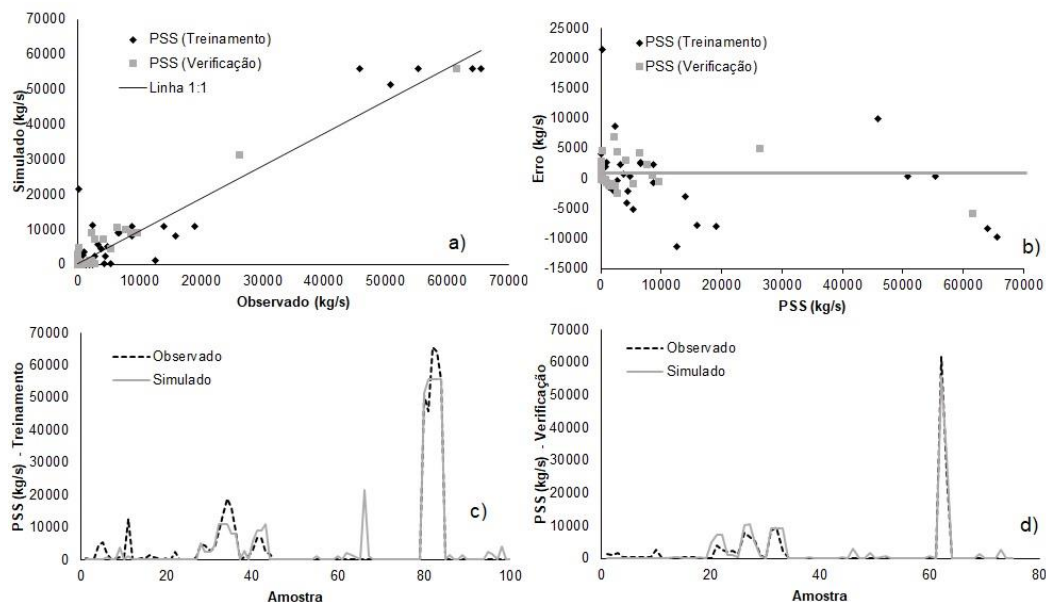
Fonte: A autora.

Figura 25 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_19.



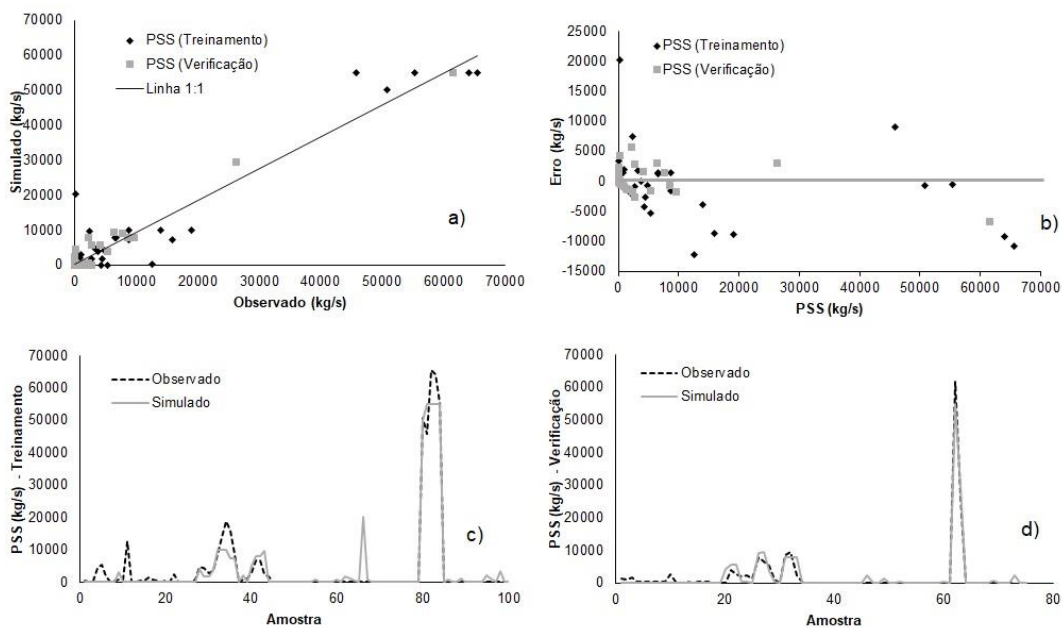
Fonte: A autora.

Figura 26- PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_20.



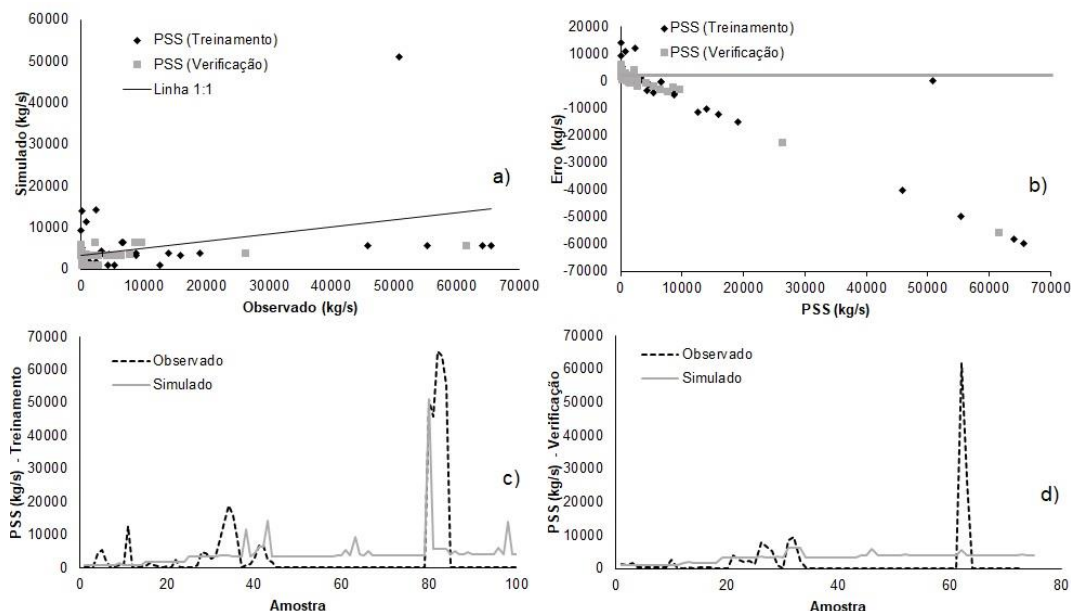
Fonte: A autora.

Figura 27- PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_21.



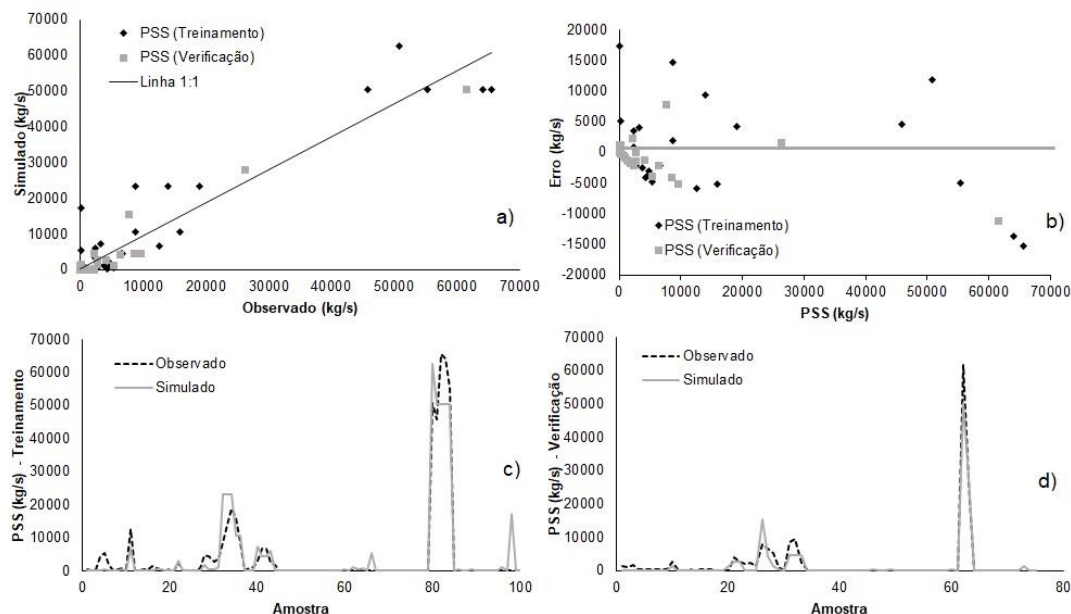
Fonte: A autora.

Figura 28 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_27.



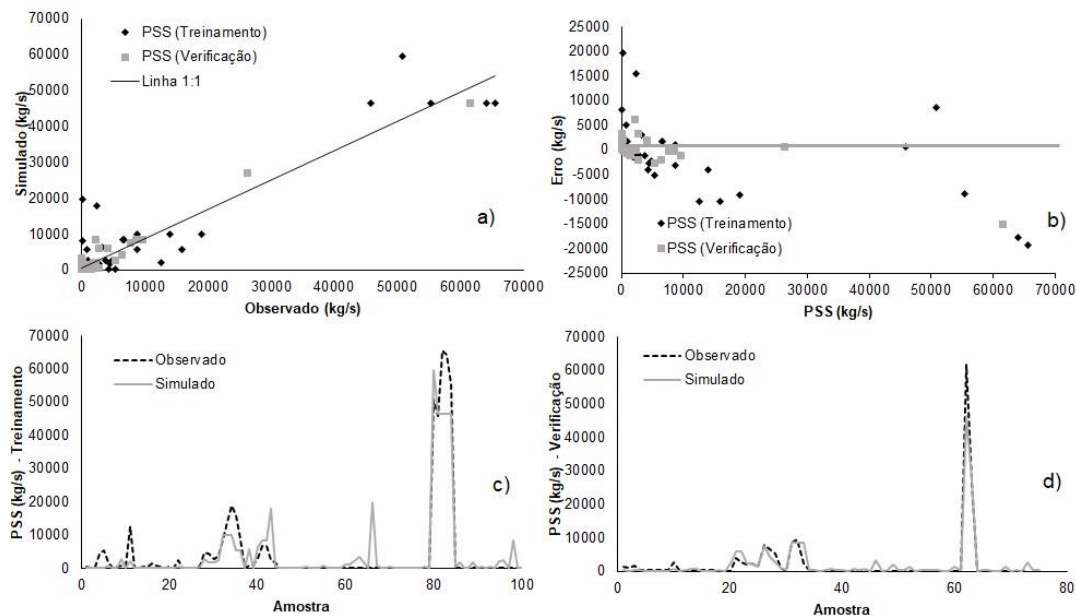
Fonte: A autora.

Figura 29 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_28.



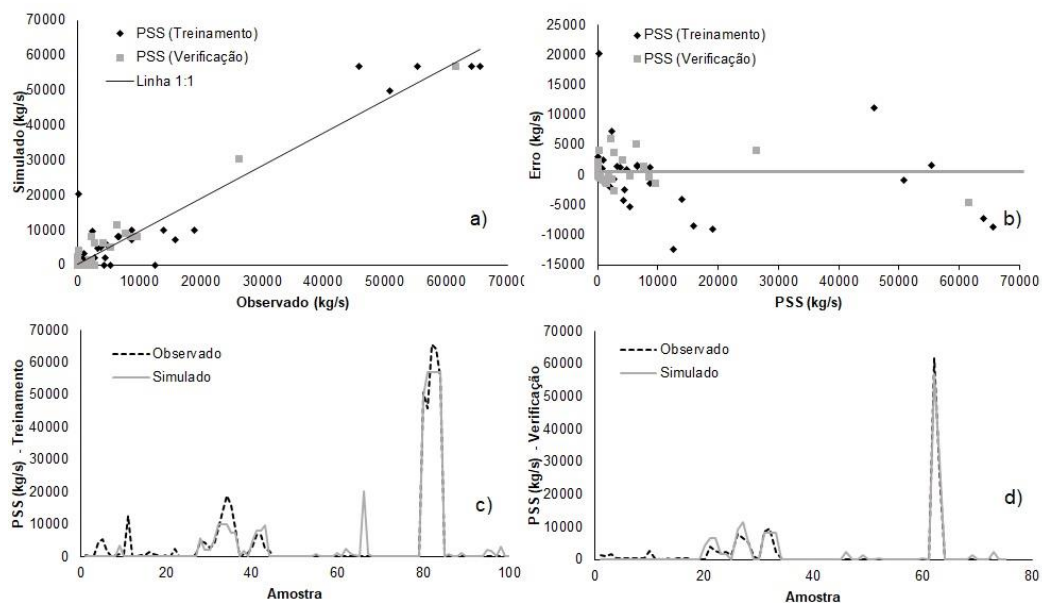
Fonte: A autora.

Figura 30 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_37.



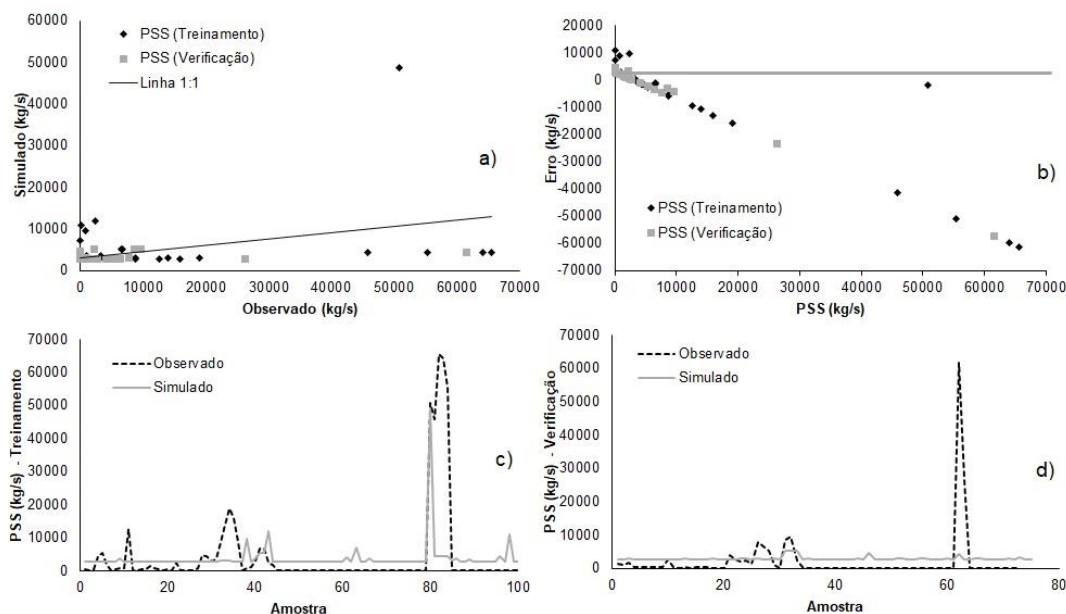
Fonte: A autora.

Figura 31 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_46.



Fonte: A autora.

Figura 32 - PSS observada e calculada em relação ao ajuste ideal (a), erro verificado entre os valores simulados e observados da PSS (b), e comportamento dos valores de PSS simulados e observados, considerando os processos de treinamento (c) e de verificação (d) do modelo RNA_PSS_53.



Fonte: A autora.

O melhor modelo de RNAs foi o número 21 com entrada das variáveis área, P0, P1, P2, P3, P4, P5, P6, que resultou em NS para a série de verificação igual a 0,963, Pbias igual a -2,91 e Mea igual a 723,8kg/s. Lembrando que o P0 corresponde à precipitação tri-horária no intervalo de medição de CSS e Vazão, P1 corresponde à precipitação tri-horária no intervalo anterior ao de P0, P2 corresponde à medição tri-horária no intervalo anterior ao de P1, e assim por diante. Portanto, a agregação das precipitações pelo uso de médias móveis temporais não foi importante, comparativamente à aplicação das próprias precipitações, no caso de intervalos tri-horários de acumulação destas, o que é um resultado importante, considerando a experiência anterior com o intervalo horário, para as mesmas bacias (TEIXEIRA *et al.* 2020).

Este resultado supera outros encontrados na literatura (TEIXEIRA *et al.*, 2020; CAMPO; PEDROLLO, 2021; SERRÃO *et al.*, 2022; XU; ZANG; YANG, 2021). Teixeira *et al.* (2020), utilizaram em seus modelos, também regionais, as entradas filtro média móvel exponencial de chuvas (EWMA) e área (A) para estimar a CSS para as mesmas bacias (Potiribu, Cambará, Taboão, Turcato, Alemão e Donato), porém com dados em escala temporal horária. Obtiveram um resultado para o NS na verificação igual a

0,956, para Mea igual a 56,5 mg/L e para Pbias igual a -5,54. Campo e Pedrollo (2021) utilizaram o modelo regional de RNAs perceptron de múltiplas camadas com 5 neurônios e variáveis quantitativas (turbidez, vazão, precipitação e EWMA de chuvas passadas) para representar a variabilidade temporal em cada bacia e variáveis qualitativas (área de drenagem, tipo de solo, uso da terra e inclinação média da bacia) para estimar a CSS na bacia hidrográfica do Pantanal (362.380 km²), obtendo o melhor modelo com todas as variáveis de entrada combinadas com NS na verificação igual a 0,854.

Serrão *et al.* (2022) utilizaram o modelo SWAT com o intuito de analisar os impactos das mudanças no uso e na cobertura da terra nos processos hidrológicos e na produção de sedimentos na bacia do Rio Itacaúnas – Paraná (Brasil) com área de 42.000 km². Para dados mensais, o desempenho na calibração, utilizando dados mensais, do modelo obteve um NS igual a 0,89. Xu, Zang e Yang (2021) também utilizaram o modelo SWAT com o objetivo de avaliar a resposta espaço-temporal a eventos extremos da água e sedimento na Bacia do Rio Amarelo (China), observando à eventos extremos e obtiveram um desempenho com NS igual a 0,705 e Pbias 7,1 para o rio Tonguan, e NS igual a 0,457 e Pbias 3,8 para o rio Tangnaihái.

Uma vez que o modelo 21, com Área da bacia, P0, ..., P6 de chuvas tri-horárias é o melhor modelo, este será utilizado para a estimativa da PSS com os dados observados e com os dados resultantes dos cenários climáticos de cada bacia, ou seja, com os dados de precipitação medida nas bacias no período de 1990 a 2020 e os dois cenários futuros RCP 4.5 e RCP 8.5 representados pelos dados de precipitação simulada pelo modelo climático regional Eta-HadGEM2-ES, após a correção do viés destes dados.

6.2 RESULTADOS DA PSS PARA OS DIFERENTES CENÁRIOS CLIMÁTICOS SIMULADOS PELO MODELO ESCOLHIDO

Neste estudo, as simulações do modelo RNA_PSS_21 com entradas (Área, P0, P1, P2, P3, P4, P5, P6) para a estimativa da PSS foram projetados para os diferentes cenários climáticos (observado – 1990 a 2020) e cenários simulados no futuro com o modelo Eta-HadGEM2-ES (RCP 4.5 - otimista e RCP8.5 - pessimista - 2021 a 2082) e para diferentes escalas de bacia (Potiribu - 524,3 km²; Cambará - 356,1 km²; Taboão - 77,5 km²; Alemão - 19,3 km²; Turcato - 19,2 km² e Donato - 1,3 km²). Atualmente os

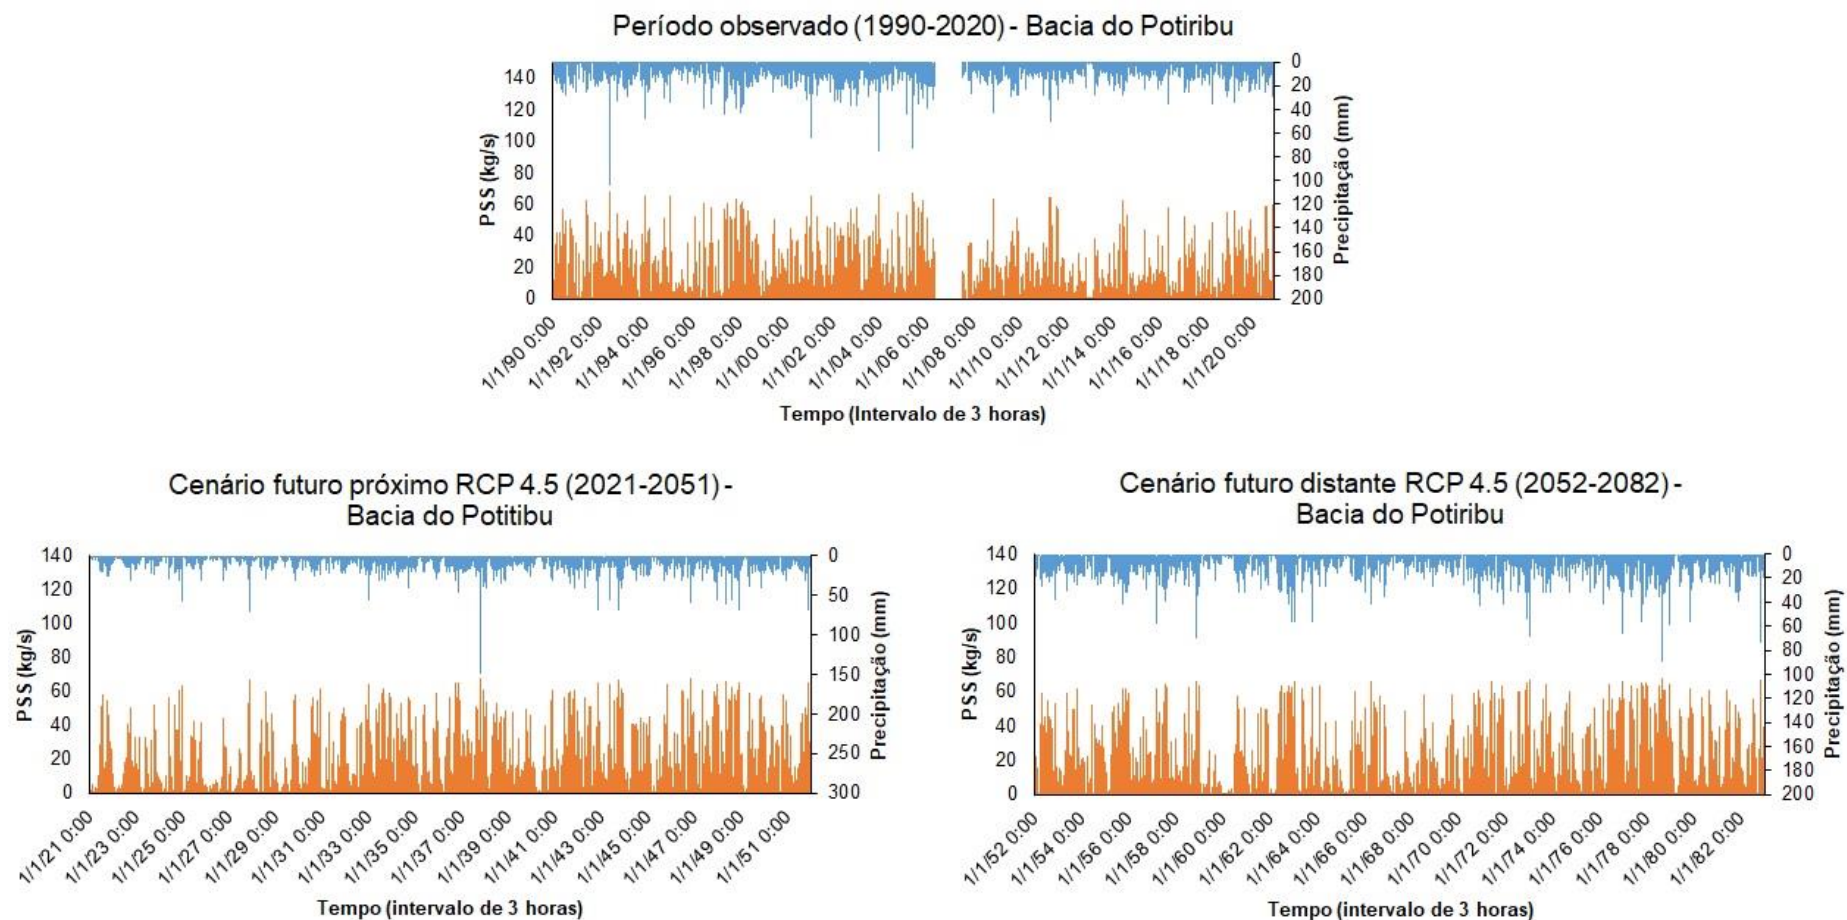
dados dos MCGs e MCRs apresentam excelentes resultados em bacias médias e grandes, porém podem conter erros sistemáticos para bacias menores, portanto não podem ser utilizados como entradas do modelo sem correção de viés (TAPIADOR *et al.* 2020; SANTOS *et al.*, 2021). Nesta pesquisa, uma abordagem de distribuição de frequência empírica de Lehner modificado foi aplicada para melhorar os dados de chuva do modelo Eta-HadGEM2-ES que foram variáveis de entrada neste estudo.

Os resultados das simulações do modelo RNA_PSS_21 com entradas (Área, P0, P1, P2, P3, P4, P5, P6) para a estimativa da PSS para os diferentes cenários climáticos (observado – 1990 a 2020) e cenários simulados no futuro com o modelo Eta-HadGEM2-ES (RCP 4.5 - otimista e RCP8.5 - pessimista - 2021 a 2082) e para diferentes escalas de bacia (Potiribu - 524,3 km²; Cambará - 356,1 km²; Taboão - 77,5 km²; Alemão - 19,3 km²; Turcato - 19,2 km² e Donato - 1,3 km²) estão apresentados nas Figuras 33 a 44.

Nas Figuras 33 a 44 são apresentados os resultados das simulações tri-horárias para cada bacia hidrográfica em estudo e seus respectivos cenários comparando a série de precipitação com a PSS. Os cenários futuros foram divididos em dois períodos um chamado de “cenário futuro próximo” o período de 2021 a 2051 e “cenário futuro distante” o período de 2052 a 2082 para uma melhor visualização das séries.


Em todos os gráficos traçados observa-se a tendência do comportamento dos eventos de chuva sendo gerado na sequência a PSS o qual é muito parecido em todas as bacias. Porém, como são dados tri-horários e os períodos muito longos optou-se em realizar uma análise mais detalhada em relação aos meses para os mesmos períodos que estão apresentados no item 6.4.

Figura 33 – Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Potiribu para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.




Fonte: A autora.

Figura 34 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Potiribu para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.




Fonte: A autora.

Figura 35 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Cambará para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.




Fonte: A autora.

Figura 36- Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Cambará para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.



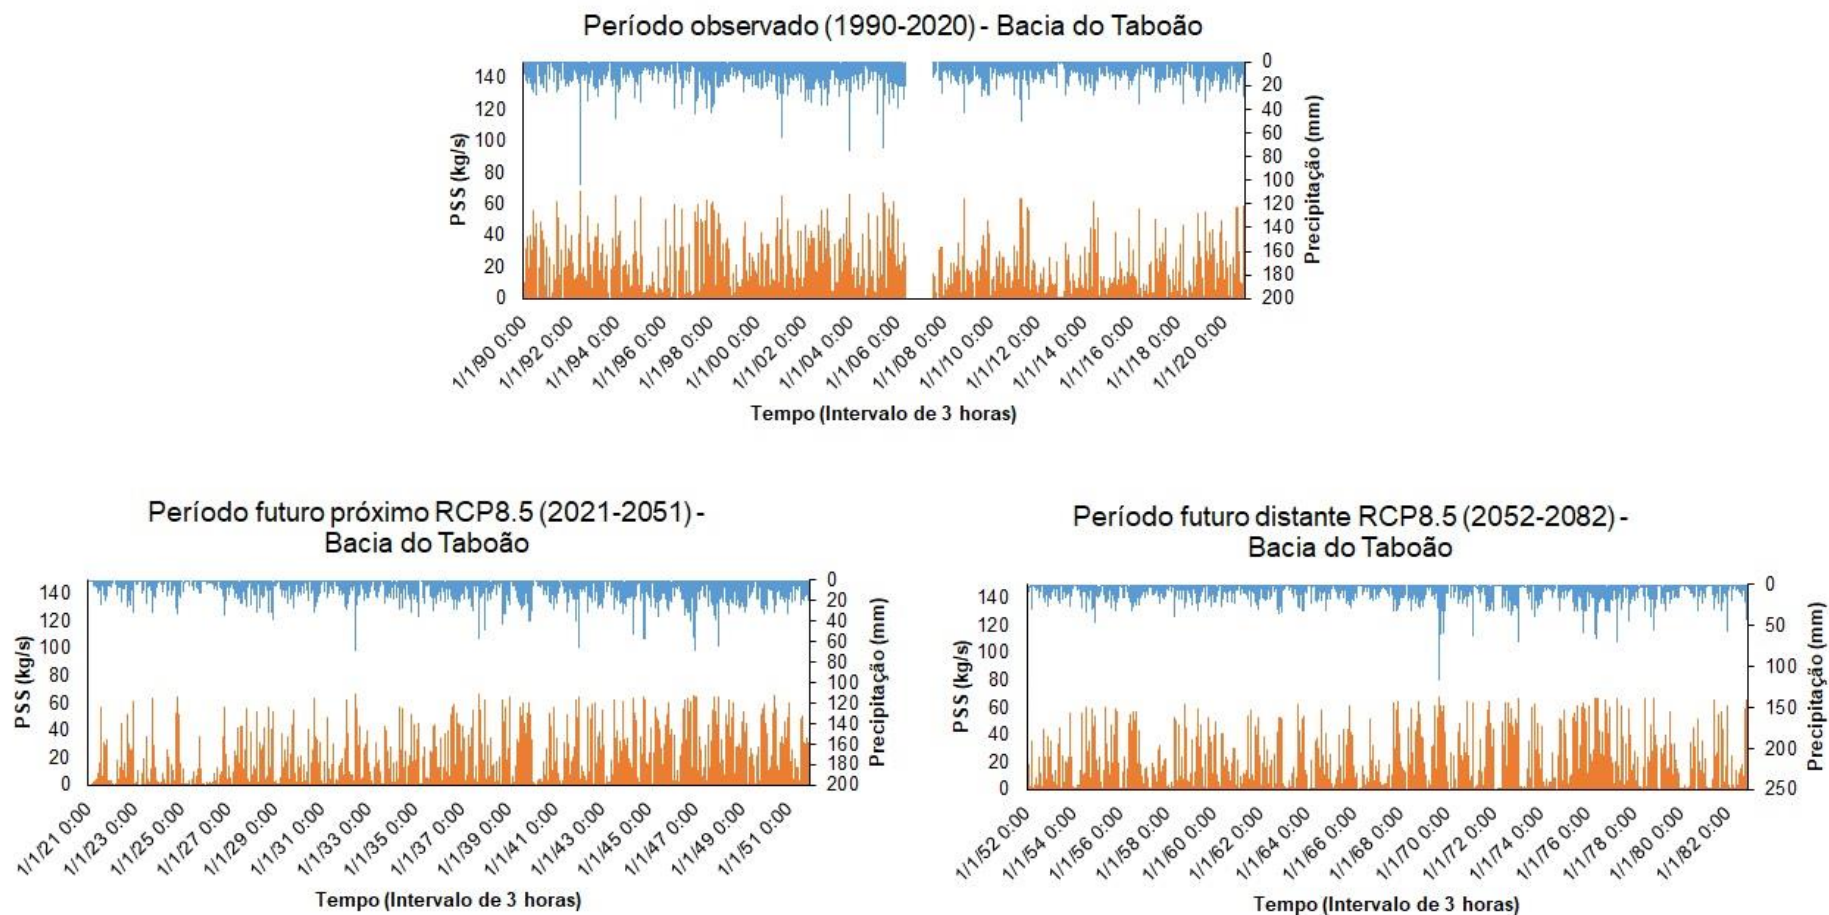
Fonte: A autora.

Figura 37 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Taboão para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.



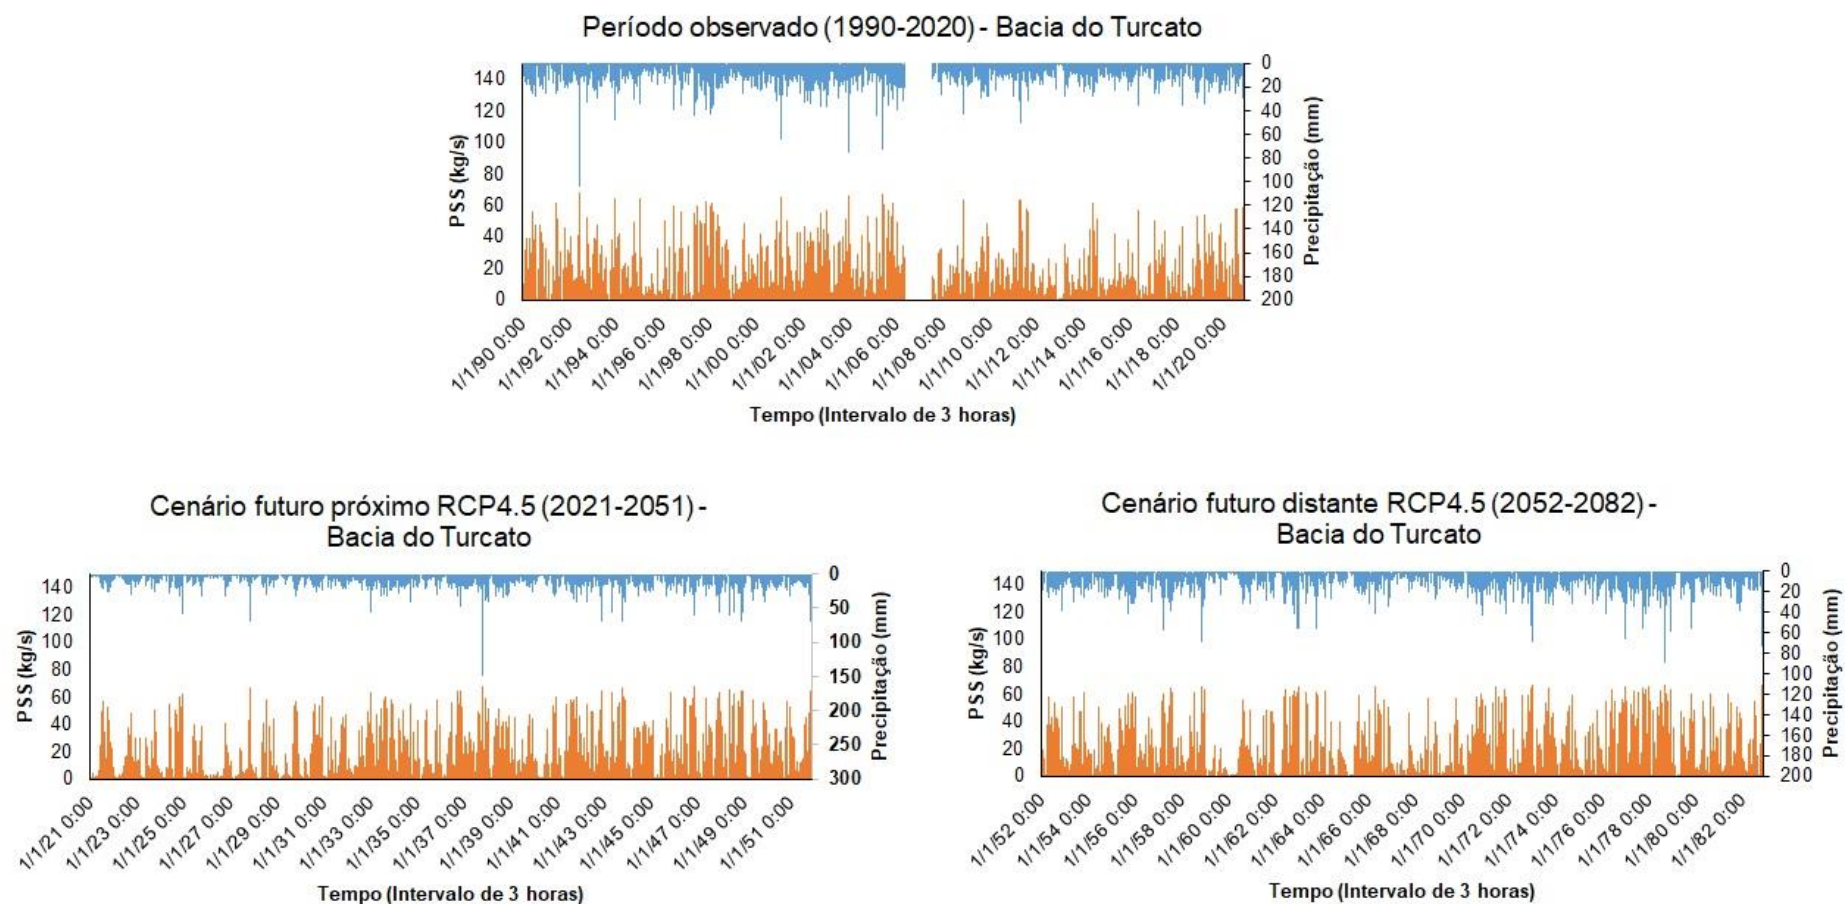
Fonte: A autora.

Figura 38 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Taboão para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.



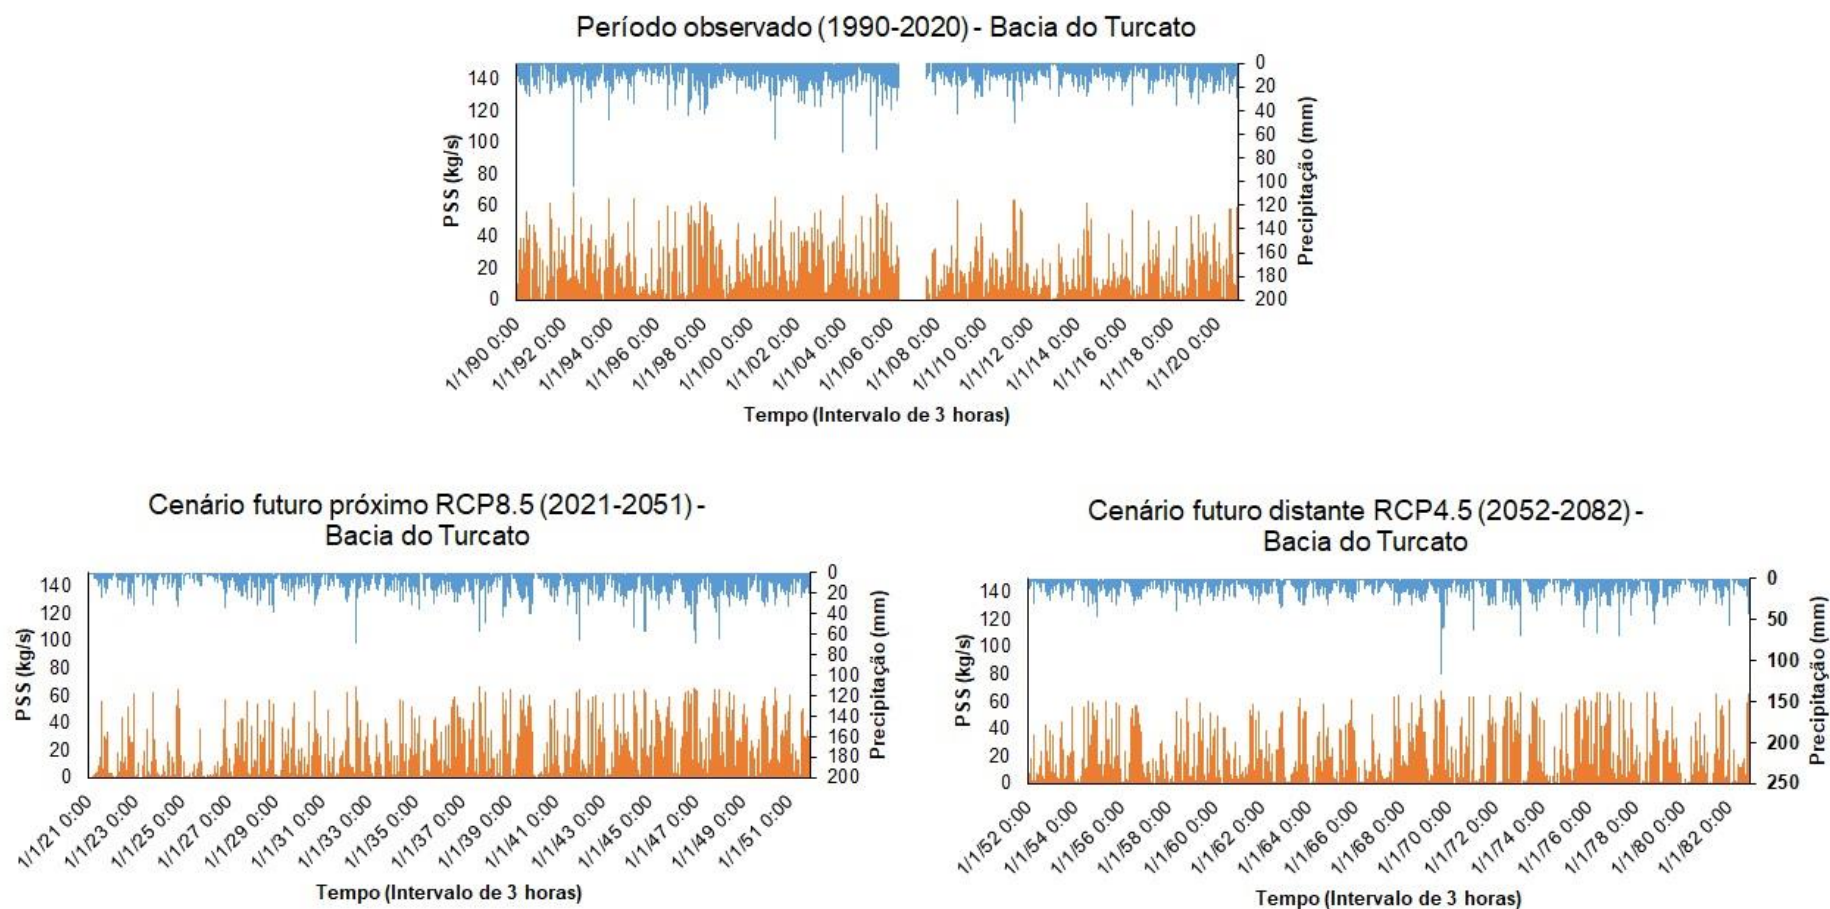
Fonte: A autora.

Figura 39- Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Turcato para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.




Fonte: A autora.

Figura 40 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Turcato para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.




Fonte: A autora.

Figura 41 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Alemão para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.




Fonte: A autora.

Figura 42 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Alemão para os cenários climáticos futuros próximo e distante do RCP 85 comparado com o período observado.




Fonte: A autora.

Figura 43 - Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Donato para os cenários climáticos futuros próximo e distante do RCP 4.5 comparado com o período observado.



Fonte: A autora.

Figura 44-Série temporal da precipitação e da PSS simuladas pelo modelo RNA da Bacia do Donato para os cenários climáticos futuros próximo e distante do RCP 8.5 comparado com o período observado.




6.3 ANÁLISE DO COMPORTAMENTO SAZONAL DAS SÉRIES TEMPORAIS SIMULADAS PELO MODELO RNA NOS CENÁRIOS CLIMÁTICOS

Para todas as bacias o teste de Phillips-Perron (PHILLIPS; PERRON, 1988), resultou em um p-valor menor ou igual a 0,01, de forma que, em todos os casos, rejeita-se a hipótese nula ao nível de 95% e conclui-se que as séries são estacionárias, podendo-se prosseguir com as análises da sazonalidade.


Assim, foram utilizadas as ferramentas existentes para este estudo de séries temporais para a análise de sazonalidades, a saber, o periodograma e os gráficos da função de autocorrelação (FAC) e autocorrelação parcial (FACP). Estas ferramentas, porém, não admitem a presença de dados faltantes na série a ser analisada, de forma que se faz necessário o preenchimento dos dados faltantes em todas as bacias e também nos dados sobre precipitação. Para isso, dada as características da série, os dados faltantes de cada série foram preenchidos com as respectivas médias mensais calculadas a partir dos dados presentes no banco. As Figuras 45 a 50 apresentam as séries originais (linha preta) e os dados preenchidos (linha vermelha). Observa-se que como são poucos os dados faltantes, o preenchimento com as médias sazonais é bastante seguro e pouco impacta as estatísticas a serem calculadas.

Figura 45 – Série observada da precipitação preenchida com médias sazonais (linha vermelha) no período de 1990 a 2020.




Fonte: A autora.

Figura 46 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Potiribu no período de 1990 a 2020.




Fonte: A autora.

Figura 47 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Cambará no período de 1990 a 2020.




Fonte: A autora.

Figura 48 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Taboão no período de 1990 a 2020.




Fonte: A autora.

Figura 49 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Alemão no período de 1990 a 2020.



Fonte: A autora.


Figura 50 - Série de PSS preenchida com médias sazonais (linha vermelha) da bacia do Donato no período de 1990 a 2020.



Fonte: A autora.


Nas figuras 51 a 57 apresentam os resultados da FAC e da FACP de cada uma das bacias e também da precipitação, calculados a partir dos dados preenchidos. As linhas azuis são o intervalo de confiança aproximado para a autocorrelação, ao nível de 95%.

Figura 51- Resultado da FAC e da FACP dos dados de precipitação no período observado de 1990 a 2020.




Fonte: A autora.

Figura 52- Resultado da FAC e da FACP da série de PSS da bacia do Potiribu no período observado de 1990 a 2020.




Fonte: A autora.

Figura 53- Resultado da FAC e da FACP da série de PSS da bacia do Cambará no período observado de 1990 a 2020.




Fonte: A autora.

Figura 54 - Resultado da FAC e da FACP da série de PSS da bacia do Taboão no período observado de 1990 a 2020.




Fonte: A autora.

Figura 55- Resultado da FAC e da FACP da série de PSS da bacia do Turcato no período observado de 1990 a 2020.




Fonte: A autora.

Figura 56- Resultado da FAC e da FACP da série de PSS da bacia do Alemão no período observado de 1990 a 2020.



Fonte: A autora.

Figura 57 - Resultado da FAC e da FACP da série de PSS da bacia do Donato no período observado de 1990 a 2020.



Fonte: A autora.


Quando existe a presença clara de sazonalidade, o gráfico da FAC revela um comportamento também sazonal, sendo que deste comportamento podemos extrair o período sazonal, se existente. O comportamento dos gráficos (Figura 51, 52, 53, 54, 55, 56, 57) revela apenas uma curta dependência serial nos dados, de lag 1 e 2 na maioria dos casos, mas não há indicativo da presença de um comportamento sazonal claro nas séries analisadas. Chama a atenção a similaridade entre os gráficos das diversas bacias e da precipitação.

Outra ferramenta bastante utilizada para a detecção de sazonalidades é o periodograma (Figura 58 a 64). Picos no periodograma são indicativos que naquelas frequências algum fenômeno importante está ocorrendo. Nem sempre este fenômeno é uma sazonalidade, mas havendo a presença de sazonalidades, estas são detectadas no periodograma.

Nas Figuras 58 a 64 são apresentados os periodogramas para as 6 bacias hidrográficas (Potiribu, Cambará, Taboão, Turcato, Alemão e Donato) e também para a precipitação. Assim, como no caso dos gráficos da FAC e FACP, os periodogramas são todos muito parecidos, todos indicando não haver sazonalidade.


Portanto, embora faça sentido físico o comportamento da precipitação e, por consequência, da PSS nas bacias, terem um padrão cíclico anual, este não se revela significativo na série temporal, muito provavelmente pela diferença pequena entre picos e vales nas médias mensais em relação à variabilidade das séries.

Figura 58 - Periodograma da série de precipitação no período observado (1990 a 2020).




Fonte: A autora.

Figura 59 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Potiribu.




Fonte: A autora.

Figura 60 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Cambará.




Fonte: A autora.

Figura 61 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Taboão.




Fonte: A autora.

Figura 62 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Turcato.




Fonte: A autora.

Figura 63 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Alemão.



Fonte: A autora.

Figura 64 - Periodograma da série de PSS no período observado (1990 a 2020) na bacia do Donato.




Fonte: A autora.

Para a comparação e a verificação do comportamento mensal da PSS no período observado (1990 a 2020) entre as bacias e a série de precipitação, as médias sazonais foram calculadas, ignorando-se os valores faltantes das séries de cada uma das 6 bacias e também da precipitação. De cada uma das médias sazonais, subtraiu-se a média de cada ano (isto é, a média calculada sobre os 12 meses), de forma que as séries fiquem centradas em zero, facilitando a interpretação.


Na Figura 65 são apresentadas as médias sazonais. Observa-se que as médias mensais da PSS possuem um comportamento muito similar para todas as bacias, sendo que a principal diferença é a média anual que tende a ser maior para bacias maiores. Outro ponto marcante da figura é a semelhança do comportamento das médias mensais da PSS em relação à precipitação, sendo que picos (vales) no gráfico da precipitação são acompanhados por picos (vales) na PSS das bacias. Isso implica a correlação muito forte (acima de 0,95) entre a PSS das bacias entre si e a precipitação na região, o que pode ser verificado na matriz de correlação na Figura 66.

Figura 65 – Comparativo entre as médias sazonais da PSS de cada bacia e a média sazonal da precipitação em zero no período observado (1990 a 2020).



Fonte: A autora.


Figura 66 – Matriz de correlação entre as séries de PSS mensal e a série de precipitação mensal no período de 1990 a 2020.



Fonte: A autora.


Uma outra maneira de visualizar este resultado é olhar para os gráficos de dispersão da PSS em cada bacia em função da precipitação. Nas Figuras 67 a 72 o eixo x representa a precipitação e o eixo y a PSS das diferentes bacias. Adicionalmente, a linha vermelha representa a equação linear obtida ajustando-se a respectiva PSS em função da precipitação. Os comportamentos dos gráficos também sugerem fortemente a presença de uma alta correlação entre a PSS das bacias e a precipitação, caracterizada pela concentração dos valores de PSS ao redor da função ajustada.

Figura 67 – Gráfico da dispersão da precipitação em função da PSS da bacia do Potiribu.




Fonte: A autora.

Figura 68 - Gráfico da dispersão da precipitação em função da PSS da bacia do Cambará.




Fonte: A autora.

Figura 69 - Gráfico da dispersão da precipitação em função da PSS da bacia do Taboão.




Fonte: A autora.

Figura 70 - Gráfico da dispersão da precipitação em função da PSS da bacia do Turcato.




Fonte: A autora.

Figura 71 Gráfico da dispersão da precipitação em função da PSS da bacia do Alemão.



Fonte: A autora.

Figura 72 - Gráfico da dispersão da precipitação em função da PSS da bacia do Donato.



Fonte: A autora.

6.4 COMPARAÇÃO DAS PROJEÇÕES DOS CENÁRIOS FUTUROS COM O PERÍODO OBSERVADO

Para estas análises de comparação entre os cenários climáticos futuros e o período observado foram traçados gráficos mensais de precipitação e de PSS para os diferentes cenários climáticos (período observado – 1990 a 2020), cenários futuros RCP 4.5 e RCP 8.5 (futuro próximo – 2021 a 2051; futuro distante – 2052 a 2082). Com a finalidade de comparar e verificar o quanto variou entre os meses e entre os cenários com relação ao período observado.

Na Figura 73 são apresentados os cenários futuros projetados da série precipitação (barra laranja) comparados com o período observado (barra azul). Observa-se que há uma tendência de redução das chuvas nos meses de janeiro a


abril em três cenários: futuro próximo RCP4.5 (-29,9%, -43,3%, -44,1%, -17,4%, respectivamente) e RCP 8.5 (-22%, -48,4%, -41%, -26,1%, respectivamente) e futuro distante RCP8.5 (-43,5%, -45,7%, -54%, -16,8%, respectivamente). Observa-se também que o mês com maior redução significativa foi o mês de março (-54%) no cenário futuro distante RCP8.5. A partir do mês de maio ocorre um aumento nas precipitações para os três cenários futuro próximo RCP4.5 (30,1%, 27,5%, 11%, 59,3%, 47%, 56,7%, 93,5%, 13,4%, respectivamente) e RCP 8.5 (8,1%, 16,9%, 1%, 35,8%, 81,3%, 28,3%, 53,9%, 36,8%, respectivamente) e futuro distante RCP8.5 (10,2%, 24,9%, 14,7%, 66,3%, 80,2%, 36%, 76,8%, respectivamente) e em dezembro ocorre uma redução de -6,7% neste cenário. Observa-se que o mês que houve um aumento mais significativo comparado com o período observado foi novembro para o cenário futuro próximo RCP4.5 com 93,5%.

O cenário futuro distante RCP 4.5 tem um comportamento um pouco diferente sendo a redução das chuvas de janeiro a março com -45,5%, -45,3%, -34,3%, respectivamente, e um aumento da chuva a partir de abril até dezembro com 4,5%, 28,1%, 35,3%, 59,7%, 60,7%, 27,8%, 78,2%, 30,8%, respectivamente.

Observa-se nestes gráficos a tendência no futuro se ter outono, inverno e verão mais secos e a primavera mais chuvosa.

Isso vai de encontro com o relatório do IPCC (2022) que relata “Desde meados do século 20, o aumento da precipitação média tem impactado positivamente a produção agrícola no sudeste da América do Sul, embora estiagens extremamente longas tenham se tornado mais frequentes, afetando as economias das grandes cidades do sudeste do Brasil. Por outro lado, a precipitação reduzida e as estações de chuva alteradas estão afetando a agricultura de subsistência de sequeiro, particularmente no Corredor Seco na América Central e nos Andes tropicais, comprometendo a segurança alimentar”.

Figura 73 – Comparação das séries de precipitação mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082).



Fonte: A autora.

Nas figuras 74, 75, 76, 77, 78 e 79 são apresentados os cenários futuros projetados da série de PSS (barra laranja) comparados com o período observado (barra azul) para a bacia do Potiribu, Cambará, Taboão, Turcato, Alemão e Donato, respectivamente. Observa-se que em todas as bacias a tendência é de reduzir a PSS nos meses de janeiro a abril para os cenários futuros próximo RCP4.5 e RCP8.5 e cenário futuro distante RCP8.5. E para estes mesmos cenários a PSS observada aumenta a partir dos meses de maio a dezembro e os cenários futuros aumenta ainda mais nesses meses variando de 4,4% a 122,7%, obtendo maior aumento no mês de novembro na bacia do Potiribu com 97,1%, Cambará com 111,5%, Taboão com 120,9%, Turcato e Alemão com 122,3% e Donato com 122,7% para o cenário futuro próximo RCP4.5.

Diferente do que foi observado na pesquisa de Oliveira *et al.* (2019) que investigaram os impactos das mudanças climáticas na hidrologia e na produção de sedimento em uma bacia de cabeceira do rio Paranaíba (Minas Gerais-Brasil) com área de 3754 km² e obtiveram em suas simulações com o modelo Eta-HadGEM2-ES para o período seco, um aumento nas cargas de sedimentos de 8,9 a 85,3% no cenário RCP4.5, entre abril a agosto, e um aumento de 5,4 a 45,8% no cenário RCP8.5.

Percebe-se que este aumento da PSS é compatível com os meses de plantio da soja em outubro a dezembro conforme CONAB (2019) principalmente no início quando o solo ainda está desprotegido e nas épocas de colheita, assim, evidencia também a relação com o aumento das precipitações nestes mesmos períodos.


Além disso, percebe-se que há uma tendência do aumento da precipitação nos meses de maio a dezembro e, conseqüentemente, também há uma tendência do aumento da PSS nesses mesmos meses, isso é uma evidência que a precipitação é o fator mais sensível que afeta a PSS, o mesmo foi encontrado e evidenciado por Zhang *et al.* (2019) que avaliaram os impactos potenciais do clima na mudança no escoamento e na produção de sedimentos em bacias hidrográficas de Zhenjianguan, localizada na região nordeste do planalto Tibetano - China (área = 4500 km²), utilizando um modelo de regressão entre fatores climáticos e fatores de cobertura vegetal e um modelo hidrológico distribuído (*Soil and Water Assessment Tool* - SWAT) com base física. Os autores constataram que a precipitação é o fator mais sensível que afeta o escoamento e a produção de sedimentos na bacia, e uma mudança anual de 10% na precipitação pode causar uma alteração de 10% a 14% no escoamento

anual e uma alteração de 17% a 24% na produção anual de sedimentos sendo cada aumento de 0,7°C na temperatura resultando em reduções de 1,4% a 2% no escoamento anual e de 2% à 3,7% na produção anual de sedimentos.

E também por Santos et al. (2021) que destacou em sua pesquisa que os maiores valores de vazão e produção de sedimentos no cenário RCP4.5 ocorreram em 2041–2070, enquanto no cenário RCP8.5, os valores mais elevados ocorreram na primeira parte do século (2014–2040). E mencionam que essa tendência está relacionada ao padrão de chuva dos cenários RCP 4.5 e 8.5, pois no RCP 4.5 o período mais chuvoso é 2041–2070, e no RCP 8.5 é 2014–2040. Os autores sugerem que mesmo em um futuro próximo (2014–2040) a médio (2041–2070) pode haver impactos negativos na dinâmica da bacia do rio Tapacurá (Pernambuco/Brasil) incluindo enchentes, assoreamento em rios e reservatórios, e reduzindo a capacidade produtiva dos solos.


Cabe ressaltar que nesta pesquisa não foi considerada nas simulações a cobertura e uso do solo, embora considere-se estas variáveis bastante importantes, e que influenciam o comportamento da PSS.

Figura 74 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Potiribu.




Fonte: A autora.

Figura 75 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Cambará.




Fonte: A autora.

Figura 76 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Taboão.




Fonte: A autora.

Figura 77- Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Turcato.




Fonte: A autora.

Figura 78 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Alemão.



Fonte: A autora.

Figura 79 - Comparação das séries de PSS mensal no período observado (1990 a 2020) com as projeções futuras em diferentes cenários futuros RCP4.5 e RCP8.5 para período futuro próximo (2021 a 2051) e período futuro distante (2052 a 2082) na bacia do Donato.



Fonte: A autora.

Para a comparação entre os cenários futuros próximo e distante do otimista (RCP4.5) e o pessimista (RCP8.5) foi selecionada a maior bacia (Potiribu) para a elaboração da tabela e o gráfico. Visto que os dados de precipitações são homogêneos para todas as bacias e a tendência é de se ter um comportamento parecido entre ambas, conforme pode ser observado nas Figuras 81 e 82.

Na Tabela 14 e na Figura 80 estão apresentadas as médias mensais de PSS para o período observado e os cenários climáticos futuros simulados nesta pesquisa para a bacia do rio Potiribu. Percebe-se que para o futuro próximo, daqui a 30 anos (2021-2051), a PSS no cenário otimista (RCP4.5) superou entre os meses de maio a agosto e nos meses de outubro e novembro o cenário pessimista (RCP8.5). No mês de maio obteve um aumento de 29,92 no RCP4.5 (2021-2051) e no RCP8.5 (2021-2051) foi de 10,68 em relação ao período observado (1990-2020). A diferença de aumento entre os cenários ainda é maior nos meses de outubro e novembro, obtendo um valor de 58,04 no RCP4.5 (2021-2051) e de 27,13 no RCP8.5 (2021-2051) no mês de outubro e um valor de 97,10 no RCP4.5 (2021-2051) e de 56,43 no RCP8.5 (2021-2051) no mês de novembro. Porém, nos meses de setembro e dezembro foi diferente no cenário pessimista (RCP8.5) que superou o otimista com valor de 83,72 para 47,47 no RCP4.5 e 41,19 para 13,57 no RCP4.5, respectivamente.

Observa-se que a tendência, mesmo que, considerando que as emissões de gases sejam as menores possíveis simuladas no cenário otimista, percebe-se que já se tem uma alteração significativa da influência das mudanças climáticas em relação as precipitações e a PSS nesta bacia em estudo nos próximos 30 anos. E que tende a aumentar nestes mesmos meses para o futuro distante (2052-2082) daqui a 60 anos. Como pode ser observado na Tabela 14 e na Figura 80 onde mostra que no mês de maio no RCP4.5 para o futuro próximo (2021-2051) foi de 29,39 e para o futuro distante foi igual a 30,97. O mesmo ocorre para os meses de junho a setembro e o mês de dezembro, sendo exceção os meses de outubro e novembro que no futuro distante ocorre um aumento menor do que o futuro próximo para este cenário.


Tabela 14 – Médias mensais de produção de sedimentos em suspensão (PSS) e variação delta (%) para os cenários climáticos futuros RCP4.5 e RCP8.5 e período observado para a bacia do potiribu.

CENÁRIOS	Média de PSS TOTAL em kg/s											
	JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
OBS (1990-2020)	383,00	262,83	307,27	350,02	373,56	388,05	351,45	274,48	330,80	555,98	330,67	332,64
RCP4.5 (2021-2051)	271,73	164,29	172,89	280,56	485,41	456,74	402,73	458,05	487,84	878,64	651,73	377,78
RCP4.5 (2052-2082)	222,74	153,47	198,75	365,34	489,25	531,28	521,41	417,30	560,29	714,97	572,72	448,07
RCP8.5 (2021-2051)	306,19	152,82	180,67	256,44	413,45	432,54	368,89	365,59	607,75	706,82	517,27	469,66
RCP8.5 (2052-2082)	242,63	143,28	149,14	295,12	421,27	449,15	414,12	475,42	607,51	758,71	578,74	295,70
DELTA (%)												
RCP4.5 (2021-2051)	-29,05	-37,49	-43,73	-19,84	29,94	17,70	14,59	66,88	47,47	58,04	97,10	13,57
RCP4.5 (2052-2082)	-41,84	-41,61	-35,32	4,38	30,97	36,91	48,36	52,03	69,37	28,60	73,20	34,70
RCP8.5 (2021-2051)	-20,06	-41,85	-41,20	-26,74	10,68	11,47	4,96	33,19	83,72	27,13	56,43	41,19
RCP8.5 (2052-2082)	-36,65	-45,49	-51,46	-15,68	12,77	15,75	17,83	73,21	83,65	36,46	75,02	-11,10

*OBS – observado; JAN – Janeiro; FEV- Fevereiro; MAR – Março; ABR – Abril; JUN – Junho; JUL – Julho; AGO – Agosto; SET – Setembro; OUT – Outubro; NOV – Novembro; DEZ – Dezembro.

Fonte: A autora.

Figura 80 – Média mensal da produção de sedimentos em suspensão (kg/s) simulados para todos os cenários climáticos da bacia do potiribu.




Fonte: A autora.

Nas Figuras 81 e 82 são apresentados os gráficos com os resultados das médias mensais da PSS e da precipitação para todos os cenários climáticos simulados nesta pesquisa e para todas as bacias dividido em dois futuros: futuro próximo 2021-2051 (Figura 81) e futuro distante 2052-2082 (Figura 82).

Percebe-se nas Figuras 81 e 82 um comportamento da PSS para ambas as bacias é semelhante. Destaca-se os primeiros meses de janeiro a março para todos os cenários climáticos futuros (RCP4.5 e RCP8.5) e todas as bacias a PSS ficou abaixo do período observado, já nos meses de setembro a novembro todos superaram o período observado.


Observa-se também nestas figuras é o comportamento da PSS em relação as precipitações, sendo a tendência da PSS em acompanhar com a ocorrência das precipitações.

Figura 81 – Média mensal da Produção de sedimentos em suspensão e da precipitação para todos os cenários climáticos e para todas as bacias.



Fonte: A autora.

Figura 82 - Média mensal da Produção de sedimentos em suspensão e da precipitação para todos os cenários climáticos e para todas as bacias.



Fonte: A autora.

Os resultados da PSS das simulações do modelo de RNA são influenciados pelo modelo climático Eta CEPTEC/INPE utilizado e pela correção de viés selecionada na modelagem. Além disso, este estudo está limitado principalmente pelo domínio dos dados observados como, a vazão variando de 0,02 a 66,05m³/s; a precipitação variando de 0 a 104,37 mm a cada três horas; a CSS variando de 1,79 a 1308,54mg/L e a PSS variando de 4,55x10⁻⁵ a 6,56x10⁺¹ kg/s. E retoma-se que nesta pesquisa não foi considerada nas simulações a cobertura e uso do solo, embora considere-se estas variáveis bastante importantes, e que influenciam o comportamento da PSS.

Destaca-se que para a verificação e confiabilidade dos resultados gerados pelo modelo de RNA foram comparados os valores das médias anuais de precipitação e PSS da bacia do Taboão (77,5 km²), que possui maior representatividade nas amostras de dados observados com a pesquisa de Sari (2017) realizada para a mesma bacia.

O modelo de RNA selecionado (21), estimou para esta bacia, na série observada de PSS (1990 à 2020), resultando em 2013 (937,2 mm de chuva) uma PSS de 2,053t/ha/ano; em 2014 (1392 mm) ocorreu uma PSS de 3,833t/ha/ano e em 2015 (1104 mm) houve uma PSS de 2,375t/ha/ano, ou seja, houve maior PSS para os anos com maior chuva (Apêndice A).

Sari (2017) encontrou para esses mesmos anos (2013, 2014 e 2015) 0,66; 1,92 e 2,46 t/ha/ano, respectivamente, também para a bacia do Taboão utilizando o modelo de RNA para estimar CSS. Ou seja, valores na mesma ordem de grandeza; sendo que em 2015 os valores são muito parecidos. Isso mostra que o modelo proposto nesta pesquisa está coerente com outros estudos, indicando que estimar a PSS pode ter certa confiança para cenários futuros supondo que as projeções das chuvas pelo modelo climático regional para o futuro estejam coerentes.

7 CONSIDERAÇÕES FINAIS

Nesta pesquisa foi avaliada a variação da produção de sedimentos em suspensão em dois cenários de mudanças climáticas futuras, em bacias agrícolas de diferentes escalas, com a aplicação de uma Rede Neural Artificial (RNA) regional, ajustada em um período observado (atual), com precipitações medidas (1990-2020). Para isso, realizou-se, a partir dos dados observados, uma pesquisa para a escolha da melhor configuração da rede com respeito às variáveis de entrada (considerando a área de cada bacia e as precipitações tri-horárias, seja na forma de valores acumulados a cada três horas, no período da medição e em períodos antecedentes, ou na forma agregada destes valores, com uso da média móvel Gama). O modelo escolhido resultou da aplicação, como entradas, da área e das precipitações tri-horárias, com até seis intervalos antecedentes, com NS, Pbias e Mae de 0,963, -2,91 e 723,8 kg/s, respectivamente. Um resultado interessante, pois, ao contrário de experiências anteriores com intervalos horários, a acumulação das precipitações na forma de médias móveis não apresentou vantagens em relação à utilização das próprias precipitações tri-horárias.

Para aplicação dos cenários futuros foi utilizado o modelo escolhido, sendo realizada a correção de viés aplicada às séries de precipitações futuras (cenários RCP 4.5 e RCP 8.5) geradas pelo modelo climático Eta-HadGEM2-ES. O método utilizado para a correção de viés que foi proposto nesta pesquisa foi chamado de Lehner modificado, com aproveitamento de todos os quantis das séries para gerar as distribuições de probabilidade na forma empírica, em substituição à técnica original, que aproveita somente os centis. Ganha-se, assim, em precisão e menor complexidade computacional, com um custo de tempo ainda bem razoável (da ordem de vinte minutos para todo o processamento).

Nesta pesquisa verificou-se que a mudança climática influencia na variação da produção de sedimentos em suspensão nas bacias agrícolas. Pode-se inferir que a PSS tem a tendência de aumentar nos meses de maio a dezembro para a maioria dos cenários futuros sendo maior nos meses de outubro e novembro comparados com o período observado para todas as bacias hidrográficas.

Já quanto à variável precipitação a tendência é de reduzir nos meses de janeiro a abril, e aumentar mais de 4,4% a partir de maio para quase todos os cenários

futuros. Este resultado é compatível com o que foi observado quanto à variação da PSS.

Conclui-se que modelos empíricos, do tipo das RNAs podem ser utilizados para avaliar a produção de sedimentos em suspensão, com base em resultados de modelos climáticos, para cenários futuros. Para a superação da dificuldade imposta pela escassez de dados, modelos de RNAs regionais (com integração de bacias de diferentes escalas) podem constituir um recurso importante, capaz de proporcionar viabilidade às pesquisas.

Assim, a metodologia desenvolvida pode auxiliar outras pesquisas e os setores envolvidos na adequação das práticas de uso e de manejo do solo, orientando na escolha de medidas mitigadoras dos problemas advindos da erosão do solo e da produção de sedimentos e também auxiliar no planejamento e no gerenciamento de bacias.

REFERÊNCIAS BIBLIOGRÁFICAS

ACCESS - TASK COMMITTEE ON APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN HYDROLOGY. Artificial neural networks in hydrology. I: Preliminary concepts. **Journal of Hydrologic Engineering**, [S. l.], v. 5, n. April, p. 115–123, 2000. Disponível em: <https://doi.org/https://ascelibrary.org/doi/pdf/10.1061/%28ASCE%291084-0699%282000%295%3A2%28115%29>

ADIB, A.; MAHMOODI, A. Prediction of suspended sediment load using ANN GA conjunction model with Markov chain approach at flood conditions. **KSCE Journal of Civil Engineering**, [S. l.], 2017. Disponível em: <https://doi.org/10.1007/s12205-016-0444-2>

AFAN, H. A. *et al.* ANN Based Sediment Prediction Model Utilizing Different Input Scenarios. **Water Resources Management**, [S. l.], v. 29, n. 4, p. 1231–1245, 2015. Disponível em: <https://doi.org/10.1007/s11269-014-0870-1>

AFAN, H. A. *et al.* Past, present and prospect of an Artificial Intelligence (AI) based model for sediment transport prediction. **Journal of Hydrology**, v. 541, p. 902–913, 2016. Disponível em: <http://dx.doi.org/10.1016/j.jhydrol.2016.07.048>

ARORA, V. K. *et al.* Carbon emission limits required to satisfy future representative concentration pathways of greenhouse gases. **Geophysical Research Letters**, [S. l.], v. 38, n. 5, p. 3–8, 2011. Disponível em: <https://doi.org/10.1029/2010GL046270>

ARTAXO, P. Mudanças climáticas podem inviabilizar soja e gado no Brasil. **Revista IHU on-line**. Entrevista. 2021. Disponível em: <https://www.ihu.unisinos.br/78-noticias/611869-mudancas-climaticas-podem-inviabilizar-soja-e-gado-no-brasil-entrevista-com-paulo-artaxo>

BANIHABIB, M.E. Performance of conceptual and black-box models in flood warning systems. **Cogent Eng** 3:1127798, 2016. Disponível em: <https://doi.org/10.1080/23311916.2015.1127798>

BARTELS, G. K. *et al.* Soil moisture estimation in two layers for a small watershed with neural network models: Assessment of the main factors that affect the results. **Catena**. v. 207, 2021. Disponível em: <https://doi.org/10.1016/j.catena.2021.105631>.

BAYRAM, A.; KANKAL, M.; ÖNSOY, H. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks. **Environmental Monitoring and Assessment**, [S. l.], v. 184, n. 7, p. 4355–4365, 2012. Disponível em: <https://doi.org/10.1007/s10661-011-2269-2>

BETTS, A.K.; MILLER, M.J. A New Convective Adjustment Scheme. Part II: Single Column Tests Using GATE Wave, BOMEX, ATEX and Arctic Air-Mass Data Sets. **Quarterly Journal of the Royal Meteorological Society**, v. 112, p. 693-709, 1986.

BERLATO, M. A.; CORDEIRO, A. P. A. Sinais de mudanças climáticas globais e

regionais, projeções para o século XXI e as tendências observadas no Rio Grande do Sul: uma revisão. **Agrometeoros**, Passo Fundo, v.25, n.2, p.273-302, dez 2017.

BLACK, T. L. The New NMC Mesoscale Eta Model: Description and Forecast Examples. [S. l.], v. 9, p. 265–278, 1994. Disponível em: [https://doi.org/http://dx.doi.org/10.1175/1520-0434\(1994\)009<0265:TNNMEM>2.0.CO;2](https://doi.org/http://dx.doi.org/10.1175/1520-0434(1994)009<0265:TNNMEM>2.0.CO;2)

BRAGA, ANTÔNIO DE PÁDUA; CARVALHO, ANDRÉ PONCE DE LEON F. DE; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2011. *E-book*.

BRAVO, J. M. *et al.* Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais. **Revista Brasileira de Recursos Hídricos**, [S. l.], v. 13, n. 2, p. 77–88, 2008. Disponível em: <https://doi.org/10.21168/rbrh.v13n2.p77-88>

BRÊDA, J. P. L. F. *et al.* Impactos das mudanças climáticas sobre os recursos hídricos da América do Sul através de projeções do cmip5. 2021. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2021.

BRIZZI; SOUZA; COSTA. Relação entre a infiltração da água nos solos e a estabilidade dos agregados em sistemas de manejos diferentes na bacia hidrográfica do rio São Romão – Nova Friburgo / RJ. 2019.

BUYUKYILDIZ, M.; KUMCU, S. Y. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. **Water Resources Management**, [S. l.], v. 31, n. 4, p. 1343–1359, 2017. Disponível em: <https://doi.org/10.1007/s11269-017-1581-1>

CAMPOS, J. A. **Modelagem hidrossedimentológica em escala espacial e temporal na bacia do alto paraguai utilizando redes neurais artificiais**. 2019. - Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

CAMPOS, J. A.; PEDROLLO, O. C. A regional ANN-based model to estimate suspended sediment concentrations in ungauged heterogeneous basins. **Hydrological Sciences Journal**, 2021. Disponível em: <https://doi.org/10.1080/02626667.2021.1918695>

CANADELL, J.G. *et al.* Global Carbon and other Biogeochemical Cycles and Feedbacks. In *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 673–816, doi:10.1017/9781009157896.007. 2021.

CANNON, A. J.; SOBIE, S. R.; MURDOCK, T. Q. Bias Correction of GCM Precipitation by Quantile Mapping: How Well Do Methods Preserve Changes in Quantiles and Extremes?. **Journal of Climate**, v. 28, 2015. Disponível em: DOI: 10.1175/JCLI-D-14-00754.1

CARVALHO, A. P. *et al.* **Levantamento semidetalhado dos solos da bacia do arroio Taboão (Pejuçara/Ijuí RS)**. Porto Alegre - RS: IPH/UFRGS, 1990. *E-book*.

CARVALHO, N. de C. **Hidrossedimentologia Prática**. 2. ed. Rio de Janeiro: Interciência, 2008. *E-book*.

CARVALHO, V. S. O. *et al.* Climate change impact assessment in a tropical headwater basin. **Rev. Ambient. Água**, v. 17, n. 1, e2753 - Taubaté, 2021. Disponível em: doi:10.4136/ambi-agua.2753

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. *et al.* 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.

CHEN, Y. *et al.* Multi-timescale sediment responses across a human impacted river-estuary system. **Journal of Hydrology**, [S. l.], v. 560, p. 160–172, 2018. Disponível em: <https://doi.org/10.1016/j.jhydrol.2018.02.075>

CHOU, S. C. *et al.* Downscaling of South America present climate driven by 4-member HadCM3 runs. **Climate Dynamics**, [S. l.], v. 38, n. 3–4, p. 635–653, 2012. Disponível em: <https://doi.org/10.1007/s00382-011-1002-8>

CHOU, S. C. *et al.* Assessment of Climate Change over South America under RCP 4.5 and 8.5 Downscaling Scenarios. **American Journal of Climate Change**, [S. l.], v. 03, n. 05, p. 512–527, 2014 a. Disponível em: <https://doi.org/10.4236/ajcc.2014.35043>

CHOU, S. C. *et al.* Evaluation of the Eta Simulations Nested in Three Global Climate Models. **American Journal of Climate Change**, [S. l.], v. 03, n. 05, p. 438–454, 2014 b. Disponível em: <https://doi.org/10.4236/ajcc.2014.35039>

CHOUBIN, B. *et al.* River suspended sediment modelling using the CART model: A comparative study of machine learning techniques. **Science of the Total Environment**, [S. l.], v. 615, p. 272–281, 2018. Disponível em: <https://doi.org/10.1016/j.scitotenv.2017.09.293>

CHRISTENSEN, J. H. *et al.* On the need for bias correction of regional climate change projections of temperature and precipitation. **Geophysical Research Letters**, [S. l.], v. 35, n. 20, 2008. Disponível em: <https://doi.org/10.1029/2008GL035694>

CHUENCHUM, P.; XU, M.; TANG, W. Predicted trends of soil erosion and sediment yield from future land use and climate change scenarios in the LancangMekong River by using the modified RUSLE model. **International Soil and Water Conservation Research**, v. 8, p. 213-227. 2020. Disponível em: <https://doi.org/10.1016/j.iswcr.2020.06.006>

COLLINS, W. J. *et al.* Development and evaluation of an Earth-System model - HadGEM2. **Geoscientific Model Development**, [S. l.], v. 4, n. 4, p. 1051–1075, 2011. Disponível em: <https://doi.org/10.5194/gmd-4-1051-2011>

COLLISCHONN, W.; TASSI, R. Introduzindo hidrologia. Porto Alegre: IPH/UFRGS. 2008.

CORDEIRO, A. P. A. *et al.* Tendências climáticas das temperaturas do ar no estado do Rio Grande do Sul, Sul do Brasil. **Revista Brasileira de Geografia Física**, Pernambuco, v. 9, n.3, p. 868-880, 2016.

COUTO, J. L. V. Do. Assoreamento de reservatórios. BLOG Rede dos Engenheiros Agrônomos do Brasil. 2019. Disponível: <http://agronomos.ning.com/profiles/blogs/pequena-barragem-de-terra?id=3071024%3ABlogPost%3A316448&page=2>.

CPTEC/INPE; UPF. Manual PROJETA. Disponível em: <https://projeta.cptec.inpe.br/#/tutorial>. Acesso em: 01/07/2021.

BARROS, C. A. P. de. *et al.* How water flow components affect sediment dynamics modeling in a Brazilian catchment. **Journal of Hydrology**, v. 597, 2021. Disponível em: <https://doi.org/10.1016/j.jhydrol.2021.126111>

DEPARTAMENTO DE POLÍTICAS AGRÍCOLAS E DESENVOLVIMENTO RURAL. **Radiografia da Agropecuária Gaúcha 2020**. Porto Alegre/RS, 2020. Disponível em: <https://www.agricultura.rs.gov.br/upload/arquivos/202009/26185534-radiografia-da-agropecuaria-gaucha-2020-1.pdf>.

DEPINÉ, H. *et al.* Preenchimento de Falhas de Dados Horários de Precipitação Utilizando Redes Neurais Artificiais. **Revista Brasileira de Recursos Hídricos**, [S. l.], v. 19, n. 1, p. 51–63, 2014.

DEPINÉ, H. A. **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. - Universidade Federal do Rio Grande do Sul - UFRGS, [s. l.], 2014.

DERPSCH, R. *et al.* Why do we need to standardize no-tillage research? **Soil Tillage Res.** 2014. Disponível em: <https://doi.org/10.1016/j.still.2013.10.002>.

DERECZYNSKI, C. *et al.* Downscaling of climate extremes over South America – Part I: Model evaluation in the reference climate. **Weather and Climate Extremes**, v. 29, 100273, 2020. Disponível em: <https://doi.org/10.1016/j.wace.2020.100273>

DIDONÉ, E. J.; MINELLA, J. P. G.; MERTEN, G. H. Quantifying soil erosion and sediment yield in a catchment in Southern Brazil and implications for land conservation. **J. Soils Sediments**, v. 15, p. 2334–2346. 2015. Disponível em: <https://doi.org/10.1007/s11368-015-1160-0>.

EDEN, J. M. *et al.* Skill, correction, and downscaling of GCM-simulated precipitation. **J. Climate**, v. 25, p. 3970–3984, 2012. Disponível em: doi:10.1175/JCLI-D-11-00254.1.

EDWARDS, T.; GLYSSON, D. **Field Methods for Measurement of Fluvial Sediment**.

U.S. Geological Survey, Techniques of Water-Resources Investigations, Book 3, Chapter C2. 1999.

EK, M., *et al.* Implementation of Noah Land Surface Model Advances in the National Centers for Environmental Prediction Operational Mesoscale Eta Model. **Journal of Geophysical Research**, v. 108, 8851. 2003. Disponível em: <http://dx.doi.org/10.1029/2002JD003296>

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Serviço Nacional de Levantamento e Conservação de Solos (Rio de Janeiro, RJ). Súmula da 10. Reunião Técnica de Levantamento de Solos. Rio de Janeiro: 1979. 83p. (Embrapa-SNLCS. Micelânea, 1).

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. 2011.

FAGUNDES, H. de O. Simulação dos fluxos de sedimentos na América do Sul. 2022. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2022.

FELS, S.B.; SCHWARZKOPF, M.D. The Simplified Exchange Approximation: A New Method for Radiative Transfer Calculations. **Journal of the Atmospheric Sciences**, v. 32, p. 1475-1488. 1975. Disponível em: [http://dx.doi.org/10.1175/1520-0469\(1975\)032<1475:TSEAN>2.0.CO;2](http://dx.doi.org/10.1175/1520-0469(1975)032<1475:TSEAN>2.0.CO;2)

FINCK, J. S. **Previsão em tempo atual de enchentes fluviais com redes neurais artificiais: Aplicação à bacia do rio Taquari-Antas/RS**. 2020. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.

FINCK, J. S.; PEDROLLO, O. C. Facing Losses of Telemetric Signal in Real Time Forecasting of Water Level using Artificial Neural Networks. **Water Resources Management**, v. 35, p.1119–1133, 2021. Disponível em: <https://doi.org/10.1007/s11269-021-02782-x>

FLATO; GREGORY; MAROTZKE, J. **Evaluation of climate models**. [S. l.: s. n.]. v. 9781107057E-book. Disponível em: <https://doi.org/10.1017/CBO9781107415324.020>

FUNDAÇÃO DE ECONOMIA E ESTATÍSTICA – FEE. **Características da agropecuária do RS**. 2015. Disponível em: <https://arquivofee.rs.gov.br/sinteseilustrada/caracteristicas-da-agropecuaria-do-rs/>. Acesso: 25/07/2022.

GAIGHER, C. **Turbilhão de lama ameaça águas cristalinas do Rio da Prata, em Mato Grosso do Sul**. Mato Grosso do Sul: [s. n.], 2019. Disponível em: <https://g1.globo.com/ms/mato-grosso-do-sul/noticia/2019/04/07/turbilhao-de-lama-ameaca-aguas-cristalinas-do-rio-da-prata-em-mato-grosso-do-sul.ghtml>.

GAMBIM, R. L. **Previsão em tempo atual dos níveis na laguna dos patos com base nos ventos usando redes neurais artificiais**. 2019. - Universidade Federal do Rio Grande do Sul - UFRGS, [s. l.], 2019.

GLYSSON, G. D. Sediment-transport curves. **U.S. Geological survey**. Open-File Report 87 218. 1987.

GUERRA, A. J. T. Processos erosivos nas encostas. In: GUERRA, A. J. T.; CUNHA, S. B. da (Orgs). **Geomorfologia: uma atualização de bases e conceitos**. 9ed. Rio de Janeiro: Bertrand Brasil, 2009. p.149-197.

GUDMUNDSSON, L. qmap: Statistical transformations for postprocessing climate model output. R package version 1.0-32014: [Available online at <http://cran.r-project.org/web/packages/qmap/>.]

GUPTA, H. V.; SOROOSHIAN, S.; YAPO, P. O. Status of Automatic Calibration for Hydrologic Models: Comparison with multilevel expert calibration. **Journal of Hydrologic Engineering**, [S. l.], v. 4, n. April, p. 135–143, 1999.

HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. In: 1987, San Diego, California. **Proceedings of the First IEEE International Joint Conference on Neural Networks**. San Diego, California: New York: IEEE, 1987. p. 11–14.

HECHT-NIELSEN, R. **Neurocomputing**. [S. l.]: Addison-Wesley, 1990. E-book.

HERNANI, L. C.; *et al.* Uma Resposta Conservacionista – o Impacto do Sistema Plantio Direto. In: MANZATTO, C. V.; FREITAS JUNIOR, E. de; PERES, J. R. R. (ed.). **Uso agrícola dos solos brasileiros**. Rio de Janeiro: Embrapa Solos, 2002. cap. 14, p. 151-161. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/212696/1/Uma-resposta-conservacionista-o-impacto-do-sistema-plantio-direto-2002.pdf>

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, [S. l.], v. 2, n. 5, p. 359–366, 1989. Disponível em: [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)

HOVENGA, P. A. *et al.* Earth ' s Future Special Section : The response of runoff and sediment loading in the Apalachicola River , Florida to climate and land use land cover change Earth ' s Future. [S. l.], 2016. Disponível em: <https://doi.org/10.1002/2015EF000348>.

HSU, K.L; GUPTA, H.V; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. **Water Resour Res** 31:2517–2530, 1995. Disponível em: <https://doi.org/10.1029/95WR01955>

IPCC, I. panel on C. C. **Climate Change 2007: The Physical Science Basis**. Cambridge, United Kingdom and New York: Cambridge University Press, 2007. *E-book*.

IPCC, I. panel on C. C. **Climate Change 2013: The Physical Science Basis**. Cambridge, United Kingdom and New York: [s. n.], 2013. *E-book*. Disponível em: <https://doi.org/http://dx.doi.org/10.1017/CBO9781107415324>

IPCC, I. panel on C. C. **Climate change 2014: Synthesis report**. Geneva, Switzerland.: IPCC, 2014. *E-book*. Disponível em: <https://doi.org/10.1017/CBO9781139177245.003>

IPCC, I. panel on C. C. **Global warming of 1.5°C: An IPCC Special report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change**,. Geneva, Switzerland.: IPCC, 2018. *E-book*.

IPCC, I. panel on C. C. **Climate Change 2019: Climate Change and Land**. Geneva, Switzerland.: IPCC, 2019. *E-book*.

IPCC, 2021: **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S.L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and B. Zhou (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, In press, doi:10.1017/9781009157896.

IPCC, 2022: **Climate Change 2022: Impacts, Adaptation, and Vulnerability**. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Lössche, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, 3056 pp., doi:10.1017/9781009325844.

INSTITUTO NACIONAL DE METEOROLOGIA - INMET. Normais climatológicas do Brasil. Disponível em: <https://clima.inmet.gov.br/prec>.

JANJIĆ, Z.I. Nonlinear Advection Schemes and Energy Cascade on Semi-Staggered Grids. **Monthly Weather Review**, v. 112, p. 1234-1245. 1984. Disponível em: [http://dx.doi.org/10.1175/1520-0493\(1984\)112<1234:NASAEC>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(1984)112<1234:NASAEC>2.0.CO;2)

JANJIĆ, Z.I. The Step-Mountain Eta Coordinate Model: Further Developments of the Convection, Viscous Sublayer, and Turbulence Closure Schemes. **Monthly Weather Review**, v. 122, p. 927-945. 1994. Disponível em: [http://dx.doi.org/10.1175/1520-0493\(1994\)122<0927:TSMECM>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(1994)122<0927:TSMECM>2.0.CO;2)

KHAN, M. Y. A. *et al.* Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. **International Journal of Sediment Research**, [s. l.], 2018. Disponível em: <https://doi.org/10.1016/j.ijsrc.2018.09.001>

LACIS, A.A.; HANSEN, J. A Parameterization for the Absorption of Solar Radiation in the Earth's Atmosphere. **Journal of the Atmospheric Sciences**, v. 31, p. 118-133. 1974. Disponível em: [http://dx.doi.org/10.1175/1520-0469\(1974\)031<0118:APFTAO>2.0.CO;2](http://dx.doi.org/10.1175/1520-0469(1974)031<0118:APFTAO>2.0.CO;2)

LAFDANI, E. K.; NIA, A. M.; AHMADI, A. Daily suspended sediment load prediction using artificial neural networks and support vector machines. **Journal of Hydrology**, [S. l.], v. 478, p. 50–62, 2013. Disponível em: <https://doi.org/10.1016/j.jhydrol.2012.11.048>

LAFON, T. *et al.* Bias correction of daily precipitation simulated by a regional climate model: A 535 comparison of methods, *International Journal of Climatology*, v. 33, p. 1367–1381, 2013. Disponível em: <https://doi.org/10.1002/joc.3518>

LENDERINK, G.; BUIHAND, A.; VAN DEURSEN, W. Estimates of future discharges of the river Rhine using two scenario methodologies: Direct versus delta approach. **Hydrology and Earth System Sciences**, [S. l.], v. 11, n. 3, p. 1145–1159, 2007. Disponível em: <https://doi.org/10.5194/hess-11-1145-2007>

LEHNER, F.; NADEEM, I.; FORMAYER, H. Evaluating quantile-based bias adjustment methods for climate change scenarios. **Hydrology and Earth System Sciences**, 2021. Disponível em: <https://doi.org/10.5194/hess-2021-498>

LI, H.; SHEFFIELD, J.; WOOD, E. F. Bias correction of monthly precipitation and temperature fields from Intergovernmental Panel on Climate Change AR4 models using equidistant quantile matching. **J. Geophys. Res.**, v. 115, D10101, 2010. Disponível em: [doi:10.1029/2009JD012882](https://doi.org/10.1029/2009JD012882).

LUCCHESI, L. V.; OLIVEIRA, G. G.; PEDROLLO, O. C. Attribute selection using correlations and principal components for artificial neural networks employment for landslide susceptibility assessment. **Environmental Monitoring and Assessment**, [S. l.], 2020. Disponível em: <https://doi.org/https://doi.org/10.1007/s10661-019-7968-0> (2020)

LYRA, A. *et al.* Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km

resolution. **Theoretical and Applied Climatology**, [S. l.], v. 132, n. 1–2, p. 663–682, 2017. Disponível em: <https://doi.org/10.1007/s00704-017-2067-z>

LYRA, A. Projeções de Mudanças Climáticas. **V WORKETA: Modelagem numérica de tempo e clima em mesoescala utilizando o modelo Eta - aspectos físicos e numéricos**. São José dos Campos-SP. 2016.

MAIER, H.R; DANDY G.C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environ Model Softw** 15:101–124, 2000. Disponível em: [https://doi.org/10.1016/S1364-8152\(99\)00007-9](https://doi.org/10.1016/S1364-8152(99)00007-9)

MARAUN, D. Bias Correcting Climate Change Simulations - a Critical Review. **Current Climate Change Reports**, [S. l.], v. 2, n. 4, p. 211–220, 2016. Disponível em: <https://doi.org/10.1007/s40641-016-0050-x>

MARTIN, G. M. *et al.* The Had-GEM2 Family of Met Office Unified Model Climate Configurations. **Geoscientific Model Development**, v. 4, p. 723-757. 2011. Disponível em: <http://dx.doi.org/10.5194/gmd-4-723-2011>

MARENGO, J. A. *et al.* Development of regional future climate change scenarios in South America using the Eta CPTEC/HadCM3 climate change projections: Climatology and regional analyses for the Amazon, São Francisco and the Paraná River basins. **Climate Dynamics**, [S. l.], v. 38, n. 9–10, p. 1829–1848, 2012. Disponível em: <https://doi.org/10.1007/s00382-011-1155-5>

MATOS, A. B. de; PEDROLLO, O. C.; CASTRO, N. M. dos R. Efeito do Controle de Montante de Sub-bacias Embutidas na Previsão Hidrológica de Curto Prazo com Redes Neurais: Aplicação à Bacia de Ponte Mística. **Revista Brasileira de Recursos Hídricos**, [S. l.], v. 19, n. 1, p. 87–99, 2014. Disponível em: <https://doi.org/10.21168/rbrh.v19n1.p87-99>

MCCULLOCH, WARREN S. E PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of mathematical biophysics**, [S. l.], v. 5, p. 115–133, 1943.

MELLO, K. de *et al.* Multiscale land use impacts on water quality: Assessment, planning, and future perspectives in Brazil. **Journal of Environmental Management**, v. 270, 110879, 2020. Disponível em: <https://doi.org/10.1016/j.jenvman.2020.110879>

MERTEN, G. H. *et al.* Determinação da concentração de sedimentos em suspensão em rios com o uso do turbidímetro. Curso. CPRM, IPH-UFRGS. Porto Alegre. 2011.

MESINGER, F. A Blocking Technique for Representation of Mountains in Atmospheric Models. **Rivista di Meteorologia Aeronautica**, [S. l.], v. 44, p. 195–202, 1984.

MESINGER, F. *et al.* **The step-mountain coordinate: model description and performance for cases of Alpine lee cyclogenesis and for a case of an Appalachian redevelopment.** [S. l.: s. n.] Disponível em: [https://doi.org/10.1175/1520-0493\(1988\)116<1493:TSMCMD>2.0.CO;2](https://doi.org/10.1175/1520-0493(1988)116<1493:TSMCMD>2.0.CO;2)

MESINGER, F. *et al.* The step-mountain coordinate: model description and performance for cases of Alpine lee cyclogenesis and for a case of an Appalachian redevelopment. **Meteorology and Atmospheric Physics**, [S. l.], v. 116, n. 3–4, p. 63–79, 2012. Disponível em: <https://doi.org/10.1007/s00703-012-0182-z>

MESINGER, F.; JANJUC, Z. Noise due to time-dependent boundary conditions in limited area models. **The GARP Programme on Numerical Experimentation**, [S. l.], n. 4, p. 31–32, 1974.

MINSKY, M.; PAPERT, S. **Perceptrons**. Cambridge, MA: MIT Press, 1969. *E-book*.
MOORE, R. J. Transfer functions, noise predictors and forecasting of flood events in real-time. *In*: SINGH, V. P. (org.). **Statistical Analysis of Rainfall and Runoff**. Littleton, Colorado, USA: Water Resources Publication, 1982. p. 229–250. *E-book*.

MOORE, R. J. Transfer functions, noise predictors and forecasting of flood events in real-time. *In*: SINGH, V. P. (org.). **Statistical Analysis of Rainfall and Runoff**. Littleton, Colorado, USA: Water Resources Publication, 1982. p. 229–250. *E-book*.

MORETTIN, P. A.; TOLOI, C. M. C. Análise de Séries Temporais, ABE – Projeto Fisher, Editora Blücher. 2004.

MORGAN, R. P. C. **Soil erosion and conservation**. 1ed. Estados Unidos: Longman Scientific Technical, 1986. 298p.

MORGAN, P. R. C. **Soil erosion and conservation**. 3. ed. Australia: Blackwell Publishing, 2005. *E-book*.

MORIASI, D. N. *et al.* Model Evaluation Guidelines For Systematic Quantification Of Accuracy In Watershed Simulations. **American Society of Agricultural and Biological Engineers**, [S. l.], v. 50, n. 3, p. 885–900, 2007.

MÜLLER *et al.* Uso, Manejo e Conservação do Solo. Porto Alegre/RS: Grupo A, 2021. 9786556902715. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9786556902715/>. Acesso em: 22 jul. 2022.

NASH, J. E.; SUTCLIFFE, I. V. River flow forecasting through conceptual models Part 1 - A discussion of principles. **Journal of Hydrology**, [S. l.], v. 10, p. 282–290, 1970.

NOBRE, C. A.; REID, J.; VEIGA, A. P. S. **Fundamentos Científicos das Mudanças Climáticas**. [S. l.: s. n.]. v. 1a edição *E-book*. Disponível em: http://www.inpe.br/noticias/arquivos/pdf/fundamentos_cientificos_mc_web.pdf

NOBRE, P. *et al.* Climate simulation and change in the brazilian climate model. **Journal of Climate**, [S. l.], v. 26, n. 17, p. 6716–6732, 2013. Disponível em: <https://doi.org/10.1175/JCLI-D-12-00580.1>

NOVOTNY, V.; OLEM, H. **Water Quality: Prevention, Identification, and Management of Diffuse Pollution**. New York: Van Nostrand Reinhold, 1994. *E-book*.

OLIVEIRA, G. G. De; PEDROLLO, O. C.; CASTRO, N. M. D. R. O Desempenho das Redes Neurais Artificiais (RNAs) para Simulação Hidrológica Mensal. **Revista Brasileira de Recursos Hídricos**, [S. l.], v. 19, n. 2, p. 251–265, 2014.

OLIVEIRA, G. G. **Abordagem estocástica para análise da relação entre a disponibilidade e a demanda hídrica no futuro**. 2014. - Universidade Federal do Rio Grande do Sul - UFRGS, [s. l.], 2014.

OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R. Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. **Engineering Applications of Artificial Intelligence**, [S. l.], 2015. Disponível em: <https://doi.org/10.1016/j.engappai.2015.01.001>

OLIVEIRA, M. H. C. de *et al.* Estimation of soil water content in watershed using artificial neural networks. **Hydrological Sciences Journal**, [S. l.], v. 62, n. 13, p. 2120–2138, 2017. Disponível em: <https://doi.org/10.1080/02626667.2017.1364844>

OLIVEIRA, V. A. de. *et al.* Modeling the effects of climate change on hydrology and sediment load in a headwater basin in the Brazilian Cerrado biome. **Ecological Engineering**, v.133, p. 20–31, 2019. Disponível em: <https://doi.org/10.1016/j.ecoleng.2019.04.021>

OLSSON, J. *et al.* Applying climate model precipitation scenarios for urban hydrological assessment: A case study in Kalmar City, Sweden. **Atmos. Res.**, v. 92, p. 364–375, 2009 doi:10.1016/j.atmosres.2009.01.015.

PAIVA, E. M. C. D. De; PAIVA, J. B. D. De (Org). Hidrologia aplicada à gestão de pequenas bacias hidrográficas. V. 1; Ed. 1ª, ISBN: 978-85-8868-605-2, ABRH: UFSM, 2016.

PANOFSKY, H. A.; BRIER, G. W. **Some Application of Statistics to Meteorology**, 224 pp., Pa. State Univ., University Park, Pa. 1968.

PASSOS, A. M. A.; ALVARENGA, R. C.; SANTOS, F. C. **AAD: Sistema de plantio direto**. In: NOBRE, M. M.; OLIVEIRA, I. R. de (Ed.). Agricultura de baixo carbono: tecnologias e estratégias de implantação. Brasília, DF: Embrapa, 2018. cap. 3, p. 61-104. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/188643/1/Sistema-plantio.pdf>

PEKTAS, A. O.; CIGIZOGLU, H. K. Investigating the extrapolation performance of neural network models in suspended sediment data. **Hydrological Sciences Journal**, [S. l.], v. 62, n. 10, 2017. Disponível em: <https://doi.org/10.1080/02626667.2017.1349316>

PHILLIPS, P. C. B.; PERRON, P. "Testing for a Unit Root in Time Series Regression" . *Biometrika*. v.75, n. 2, p. 335–346, 1988. Disponível em: doi:10.1093/biomet/75.2.335

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, [S. l.], v. 65, n. 6, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. [S. l.], n. 2, p. 3–6, 1986. Disponível em: <https://doi.org/https://doi.org/10.1038/323533a0>

SANIKHANI, H. *et al.* Geoderma Non-tuned data intelligent model for soil temperature estimation: A new approach. **Geoderma**, [S. l.], v. 330, n. May, p. 52–64, 2018. Disponível em: <https://doi.org/10.1016/j.geoderma.2018.05.030>

SANTOS, C. G. dos. **Erosão hídrica e taxa de entrega de sedimentos na bacia hidrográfica semiárida do riacho Exú, PE**. 2013. - Universidade Federal Rural de Pernambuco, [s. l.], 2013.

SANTOS, J. Y. G. dos. *et al.* Modeling the impacts of future LULC and climate change on runoff and sediment yield in a strategic basin in the Caatinga/Atlantic forest ecotone of Brazil. **Catena**, v. 203, 2021. Disponível em: <https://doi.org/10.1016/j.catena.2021.105308>

SARI, V. **Monitoramento e modelagem da produção de sedimentos em uma bacia hidrográfica no Noroeste do Rio Grande do Sul**. 2017. - Universidade Federal do Rio Grande do Sul - UFRGS, [s. l.], 2017.

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**, [S. l.], v. 31, n. 15, p. 4909–4923, 2017. Disponível em: <https://doi.org/10.1007/s11269-017-1785-4>

SECCO, D. *et al.* Efeito de sistemas de manejo nas propriedades físicas de um latossolo vermelho-escuro. **Ciência Rural**, Santa Maria, v.27, n.1, p.57-60, 1997. Disponível em: <https://www.scielo.br/j/cr/a/VzjZHTH3bx3Z3P6DtJLdLFS/?format=pdf&lang=pt>

SERGIEIEVA, K. **Blog Erosão Hídrica: Tipos, Causas, Efeitos e Prevenção**. 2021. Disponível em: <https://eos.com/pt/blog/erosao-hidrica/>

SHOAIB, M. *et al.* A Comparative Study of Various Hybrid Wavelet Feedforward Neural Network Models for Runoff Forecasting. **Water Resources Management**, [S. l.], v. 32, n. 1, 2018. Disponível em: <https://doi.org/10.1007/s11269-017-1796-1>

SILLMANN, J. V. *et al.* Climate extremes indices in the CMIP5 multimodel ensemble: Part 1. Model evaluation in the present climate. **J. Geophys. Res. Atmos.** v. 118, p. 1716–1733, 2013. doi:10.1002/jgrd.50203.

SILVA, E. D. **Previsão hidroeconômica de curto prazo com modelo de redes neurais artificiais: aplicação à bacia do rio Caí**. 2019. - Universidade Federal do Rio Grande do Sul, [s. l.], 2019.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. [S. l.]: Artliber, 2010. *E-book*.

SILVA, M. S. L. Estudos da erosão. Petrolina: Embrapa-CPATSA, 1995. Disponível em: <https://www.infoteca.cnptia.embrapa.br/handle/doc/133340>. Acesso em: 22 jul. 2022.

SINGH, G.; PANDA, R. K. Daily Sediment Yield Modeling with Artificial Neural Network using 10-fold Cross Validation Method: A small agricultural watershed, Kapgari, India. **International Journal of Earth Sciences and Engineering**, v. 4, n. 6, p.443-450. 2011.

SISTEMA DE ESTIMATIVA DE EMISSÕES DE GASES DE EFEITO ESTUFA - SEEG. **Análise das emissões brasileiras de gases do efeito estufa e suas implicações para as metas climáticas do Brasil 1970 – 2020**. 2021. Disponível em: https://seeg-br.s3.amazonaws.com/Documentos%20Analiticos/SEEG_9/OC_03_relatorio_2021_FINAL.pdf

SUBCOMMITTEE ON SEDIMENTATION. Determination of fluvial sediment discharge. Inter-Agency Committee on Water Resources. Report nº14. Washington, D.C. 1963.

SWITANIEL, M. B. *et al.* Scaled distribution mapping: a bias correction method that preserves raw climate model projected changes. **Hydrol. Earth Syst. Sci.**, v. 21, p. 2649–2666, 2017. Disponível em: <https://doi.org/10.5194/hess-21-2649-2017>

TEIXEIRA, W. *et al.* (Org). **Decifrando a Terra**. São Paulo: Companhia Editora Nacional, 2009.

TEIXEIRA, L. C. *et al.* Artificial Neural Network and Fuzzy Inference System Models for Forecasting Suspended Sediment and Turbidity in Basins at Different Scales. **Water Resources Management**, v. 34, p.3709–3723, 2020. Disponível em: <https://doi.org/10.1007/s11269-020-02647-9>

TENG, J., N. *et al.* How does bias correction of regional climate model precipitation affect modelled runoff? **Hydrol. Earth Syst. Sci.**, v. 19, p. 711–728, 2015. Disponível em: [doi:10.5194/hess-19-711-2015](https://doi.org/10.5194/hess-19-711-2015).

TEUTSCHBEIN, C.; SEIBERT, J. Regional climate models for hydrological impact studies at the catchment scale: a review of recent modeling strategies. **Geography Compass**, [S. l.], v. 4, n. 7, p. 834–860, 2010.

TEUTSCHBEIN, C.; SEIBERT, J. Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. **Journal of Hydrology**, [S. l.], v. 456–457, p. 12–29, 2012. Disponível em: <https://doi.org/10.1016/j.jhydrol.2012.05.052>

THEMEßI, M. J.; GOBIET, A.; HEINRICH, G. Empirical-statistical downscaling and error correction of regional climate models and its impact on the climate change signal. **Climatic Change**, v. 112, p. 449–468, 2012. Disponível em: DOI 10.1007/s10584-011-0224-42012.

TUCCI, C. (org.). **Hidrologia ciência e aplicação**. 3 ed., Porto Alegre, Editora da Universidade da UFRGS/ ABRH, 2004.

UCA *et al.* Daily Suspended Sediment Discharge Prediction Using Multiple Linear Regression and Artificial Neural Network. *In*: 2018, **Journal of Physics: Conference Series**. [S. l.: s. n.] Disponível em: <https://doi.org/10.1088/1742-6596/954/1/012030>

VIERO, A. C. **Análise da geologia, geomorfologia e solos no processo de erosão por voçorocas: Bacia do taboão, RS**. 2004. - Universidade Federal do Rio Grande do Sul, [s. l.], 2004

VRAC, M.; NOËL, T.; VAUTARD, R. Bias correction of precipitation through Singularity Stochastic Removal: because occurrences matter. [S. l.], n. 1, p. 5237–5258, 2016. Disponível em: <https://doi.org/10.1002/2015JD024511>.Received

WANG, D.; HEJAZI, M. Quantifying the relative contribution of the climate and direct human impacts on mean annual streamflow in the contiguous United States. **Water Resources Research**, [S. l.], v. 47, n. 9, 2011. Disponível em: <https://doi.org/10.1029/2010WR010283>

WARRICK, J. A. *et al.* Journal of Hydrology Trends in the suspended-sediment yields of coastal rivers of northern California , 1955 – 2010. **Journal of Hydrology**, [S. l.], v. 489, p. 108–123, 2013. Disponível em: <https://doi.org/10.1016/j.jhydrol.2013.02.041>

WATANABE, M. *et al.* Improved climate simulation by MIROC5: Mean states, variability, and climate sensitivity. **Journal of Climate**, [S. l.], v. 23, n. 23, p. 6312–6335, 2010. Disponível em: <https://doi.org/10.1175/2010JCLI3679.1>

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. **Ire wescon convention record**, [S. l.], v. 8, n. 4, p. 96–104, 1960.

WILKS, D. *Statistical Methods in the Atmospheric Sciences: an introduction*. New York: Academic Press, 1995. 467 p.

WILLEMS, P.; VRAC, M. Statistical precipitation downscaling for small-scale hydrological impact investigations of climate change. **J. Hydrol.**, v. 402, p. 193–205, 2011. Disponível em: [doi:10.1016/j.jhydrol.2011.02.030](https://doi.org/10.1016/j.jhydrol.2011.02.030).

WMO. WMO Greenhouse Gas Bulletin. **Sulphur**, [S. l.], v. 2018, n. 5, p. 5–8, 2019.

WMO - WORLD METEOROLOGICAL ORGANIZATION. WMO Greenhouse Gas Bulletin (GHG Bulletin) - No. 17. **WMO Greenhouse Gas Bulletin**, [S. l.], v. 17, n. 17, p. 1–10, 2021. Disponível em: https://library.wmo.int/doc_num.php?explnum_id=10904

YADAV, A. *et al.* Capability and Robustness of Novel Hybridized Artificial Intelligence Technique for Sediment Yield Modeling in Godavari River, India. **Water**. v. 14, 2022. Disponível em: <https://doi.org/10.3390/w14121917>

ZILLI, M. *et al.* The impact of climate change on Brazil's agriculture. **Science of the Total Environment**. 2018. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.139384>

ZHANG, S. *et al.* Impacts on watershed-scale runoff and sediment yield resulting from synergetic changes in climate and vegetation. **Catena**, v. 179, p. 129–138, 2019. Disponível em: <https://doi.org/10.1016/j.catena.2019.04.007>

ZHAO, Q.; BLACK, T.L.; BALDWIN, M.E. Implementation of the Cloud Prediction Scheme in the Eta Model at NCEP. **Weather and Forecasting**, v. 12, p. 697-712. 1997. Disponível em: [http://dx.doi.org/10.1175/1520-0434\(1997\)012<0697:IOTCPS>2.0.CO;2](http://dx.doi.org/10.1175/1520-0434(1997)012<0697:IOTCPS>2.0.CO;2)

ZORITA, E.; VON STORCH, H. The Analog Method as a Simple Statistical Downscaling Technique: Comparison with More Complicated Methods. **Journal of climate**, [S. l.], v. 12, p. 2474–2489, 1999. Disponível em: [https://doi.org/10.1175/1520-0442\(1999\)012<2474:TAMAAS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012<2474:TAMAAS>2.0.CO;2)

APÊNDICE

APÊNDICE A – Resultados das simulações do modelo de RNA para os cenários climáticos (observado, futuro – RCP4.5 e RCP8.5) das precipitações e da produção de sedimentos em suspensão para as bacias hidrográficas.

Figura 83 - Resultados de PSS e Precipitação no período observado (1990 a 2020) para as diferentes escalas de bacia.

ANO	PREC Total observada (mm)	PSS (t/ha/ano) Potiribu	PSS (t/ha/ano) Cambará	PSS (t/ha/ano) Taboão	PSS (t/ha/ano) Alemão	PSS (t/ha/ano) Turcato	PSS (t/ha/ano) Donato
1990	2061	8,356	7,307	6,441	6,284	6,283	6,236
1991	1163	4,895	3,979	3,480	3,393	3,393	3,367
1992	2016	7,320	6,303	5,531	5,392	5,392	5,350
1993	1708	6,644	5,630	4,857	4,720	4,720	4,679
1994	1854	6,678	5,631	4,726	4,563	4,562	4,514
1995	1236	4,342	3,404	2,786	2,681	2,681	2,650
1996	1751	6,622	5,602	4,809	4,664	4,664	4,620
1997	2246	9,699	8,649	7,775	7,618	7,617	7,570
1998	2147	8,654	7,590	6,683	6,516	6,516	6,466
1999	1319	4,874	3,914	3,292	3,182	3,182	3,149
2000	1540	5,914	4,914	4,196	4,069	4,069	4,031
2001	1494	5,737	4,754	4,083	3,967	3,967	3,932
2002	2359	9,690	8,589	7,639	7,461	7,460	7,407
2003	1593	6,677	5,703	5,062	4,947	4,947	4,912
2004	1187	4,521	3,580	3,017	2,920	2,919	2,891
2005	1977	8,458	7,455	6,728	6,598	6,597	6,558
2006							
2007							
2008	1277	5,072	4,119	3,558	3,458	3,458	3,428
2009	1581	6,079	5,070	4,351	4,222	4,222	4,183
2010	1254	4,491	3,545	2,930	2,822	2,822	2,790
2011	1693	6,810	5,816	5,135	5,010	5,010	4,973
2012	619,2	2,536	1,677	1,340	1,287	1,287	1,272

2013	937,2	3,430	2,523	2,053	1,973	1,973	1,949
2014	1392	5,425	4,460	3,833	3,722	3,721	3,688
2015	1104	3,889	2,952	2,375	2,276	2,276	2,246
2016	999	3,660	2,746	2,250	2,166	2,166	2,141
2017	1207	4,647	3,695	3,101	2,996	2,996	2,965
2018	1108	4,349	3,417	2,867	2,777	2,777	2,750
2019	1395	5,652	4,686	4,056	3,944	3,944	3,911
2020							
Média	1507,76	5,90	4,92	4,25	4,13	4,13	4,09
Mínima	619,20	2,54	1,68	1,34	1,29	1,29	1,27
Máxima	2359,00	9,70	8,65	7,78	7,62	7,62	7,57

Figura 84 - Resultados de PSS e Precipitação no cenário RCP4.5 (2021-2099) para as diferentes escalas de bacia.

ANO	PREC Total simulada (mm)	PSS (t/ha/ano) Potiribu	PSS (t/ha/ano) Cambará	PSS (t/ha/ano) Taboão	PSS (t/ha/ano) Alemão	PSS (t/ha/ano) Turcato	PSS (t/ha/ano) Donato
2021	1740	7,132	6,127	5,352	5,215	5,215	5,174
2022	1234	4,431	3,484	2,812	2,701	2,701	2,668
2023	1350	4,974	4,011	3,307	3,190	3,190	3,156
2024	1843	7,854	6,856	6,097	5,961	5,961	5,921
2025	1152	4,339	3,408	2,801	2,697	2,697	2,667
2026	731,9	2,798	1,931	1,489	1,421	1,420	1,401
2027	1132	4,367	3,452	2,897	2,805	2,805	2,777
2028	1107	4,451	3,532	2,971	2,878	2,878	2,850
2029	1246	4,729	3,793	3,189	3,084	3,084	3,052
2030	1837	7,210	6,187	5,363	5,217	5,217	5,173

2031	1613	6,231	5,239	4,500	4,368	4,368	4,328
2032	1474	5,598	4,624	3,910	3,787	3,787	3,750
2033	2126	9,043	8,009	7,180	7,028	7,028	6,982
2034	1918	7,766	6,732	5,905	5,754	5,754	5,709
2035	1370	5,402	4,446	3,801	3,691	3,691	3,658
2036	2027	8,109	7,083	6,245	6,094	6,094	6,049
2037	2430	9,070	8,018	7,138	6,979	6,978	6,931
2038	1751	7,052	6,047	5,297	5,160	5,159	5,118
2039	1700	6,359	5,349	4,557	4,411	4,411	4,367
2040	1208	4,723	3,796	3,225	3,127	3,127	3,098
2041	2371	10,042	8,970	8,063	7,892	7,892	7,840
2042	2099	8,551	7,495	6,614	6,453	6,453	6,404
2043	2657	10,920	9,810	8,790	8,602	8,602	8,545
2044	2088	8,165	7,090	6,161	5,993	5,992	5,942
2045	1455	5,704	4,738	4,069	3,954	3,954	3,919
2046	2675	10,889	9,793	8,796	8,611	8,611	8,555
2047	2269	9,637	8,577	7,691	7,528	7,527	7,478
2048	2815	11,881	10,766	9,770	9,580	9,580	9,523
2049	1888	7,605	6,578	5,761	5,612	5,612	5,567
2050	1741	6,952	5,947	5,202	5,064	5,064	5,023
2051	1639	6,425	5,433	4,699	4,565	4,565	4,525
2052	2165	8,833	7,764	6,862	6,695	6,695	6,645
2053	1739	6,879	5,881	5,121	4,988	4,987	4,947
2054	1637	6,293	5,292	4,524	4,386	4,386	4,345
2055	2505	10,384	9,281	8,284	8,099	8,099	8,044
2056	1609	5,728	4,722	3,932	3,791	3,791	3,749
2057	2465	9,497	8,392	7,355	7,166	7,166	7,109
2058	2501	9,994	8,902	7,895	7,710	7,710	7,654

2059	554,5	2,115	1,276	0,930	0,878	0,878	0,863
2060	1300	5,374	4,429	3,808	3,706	3,706	3,675
2061	1367	5,470	4,517	3,880	3,770	3,770	3,737
2062	2380	10,438	9,406	8,589	8,440	8,440	8,395
2063	1598	6,362	5,396	4,709	4,585	4,585	4,548
2064	1363	5,043	4,087	3,410	3,294	3,294	3,259
2065	1539	5,928	4,944	4,224	4,098	4,097	4,060
2066	1655	6,619	5,639	4,929	4,802	4,801	4,763
2067	878,5	3,219	2,329	1,824	1,745	1,745	1,722
2068	1516	5,755	4,770	4,037	3,910	3,910	3,872
2069	1554	5,638	4,648	3,874	3,742	3,742	3,702
2070	1760	7,627	6,637	5,931	5,804	5,804	5,766
2071	2108	8,702	7,682	6,853	6,706	6,706	6,662
2072	2036	8,126	7,101	6,290	6,142	6,142	6,098
2073	2180	8,611	7,553	6,636	6,465	6,465	6,414
2074	1493	5,866	4,902	4,226	4,109	4,109	4,074
2075	1425	5,344	4,374	3,676	3,554	3,554	3,517
2076	2250	9,426	8,382	7,519	7,362	7,362	7,314
2077	2477	10,884	9,851	9,029	8,880	8,879	8,834
2078	2630	11,111	10,036	9,106	8,935	8,935	8,883
2079	1833	7,351	6,328	5,543	5,398	5,398	5,354
2080	1501	5,807	4,831	4,119	3,994	3,994	3,957
2081	2192	8,799	7,734	6,817	6,649	6,649	6,598
2082	1482	5,788	4,823	4,156	4,038	4,038	4,002
2083	1458	5,229	4,249	3,494	3,368	3,368	3,331
2084	955,2	3,834	2,938	2,428	2,345	2,345	2,321
2085	1776	6,627	5,628	4,839	4,699	4,699	4,657
2086	1534	6,346	5,378	4,717	4,601	4,601	4,567

2087	1838	6,902	5,873	5,022	4,875	4,875	4,831
2088	1581	6,182	5,211	4,500	4,374	4,374	4,337
2089	1927	7,680	6,648	5,793	5,642	5,642	5,597
2090	2300	9,554	8,522	7,674	7,520	7,520	7,474
2091	2042	8,668	7,651	6,870	6,725	6,725	6,681
2092	1438	5,341	4,376	3,695	3,574	3,574	3,538
2093	1837	7,391	6,384	5,624	5,485	5,485	5,443
2094	1467	5,343	4,371	3,660	3,537	3,536	3,500
2095	1423	5,316	4,356	3,672	3,555	3,555	3,520
2096	1975	7,921	6,896	6,093	5,947	5,947	5,903
2097	2231	9,168	8,100	7,157	6,988	6,988	6,937
2098	1514	5,545	4,557	3,825	3,698	3,697	3,659
2099	1394	5,403	4,511	3,859	3,745	3,745	3,711
Média	1760,38	7,01	6,01	5,25	5,11	5,11	5,07
Mínima	554,50	2,11	1,28	0,93	0,88	0,88	0,86
Máxima	2815,00	11,88	10,77	9,77	9,58	9,58	9,52

Figura 85- Resultados de PSS e Precipitação no cenário RCP8.5 (2021-2099) para as diferentes escalas de bacia.

ANO	PREC Total simulada (mm)	PSS (t/ha/ano) Potiribu	PSS (t/ha/ano) Cambará	PSS (t/ha/ano) Taboão	PSS (t/ha/ano) Alemão	PSS (t/ha/ano) Turcato	PSS (t/ha/ano) Donato
2021	1276	4,950	4,008	3,377	3,267	3,267	3,235
2022	1642	6,500	5,520	4,809	4,679	4,679	4,641
2023	1222	4,717	3,797	3,235	3,136	3,136	3,107
2024	1120	4,554	3,652	3,140	3,054	3,053	3,028
2025	509,6	2,094	1,266	0,943	0,896	0,896	0,882

2026	1056	3,880	2,971	2,407	2,312	2,312	2,284
2027	1591	6,094	5,111	4,376	4,243	4,243	4,204
2028	1353	5,395	4,449	3,812	3,700	3,700	3,666
2029	1288	4,825	3,881	3,252	3,142	3,142	3,109
2030	1167	4,477	3,555	2,983	2,887	2,887	2,859
2031	1156	4,208	3,277	2,673	2,571	2,571	2,541
2032	1676	6,623	5,639	4,910	4,778	4,778	4,739
2033	1236	4,562	3,622	3,014	2,908	2,908	2,877
2034	1589	6,157	5,174	4,464	4,334	4,334	4,295
2035	1645	6,046	5,042	4,257	4,117	4,116	4,074
2036	2180	9,030	7,975	7,102	6,940	6,940	6,891
2037	2072	8,556	7,528	6,698	6,544	6,543	6,497
2038	1800	7,130	6,150	5,437	5,305	5,305	5,265
2039	2339	9,695	8,618	7,666	7,489	7,489	7,435
2040	1144	4,314	3,399	2,829	2,732	2,732	2,703
2041	1680	6,829	5,848	5,137	5,010	5,010	4,972
2042	1836	7,357	6,361	5,604	5,466	5,466	5,424
2043	1880	7,402	6,384	5,570	5,421	5,421	5,376
2044	1840	7,483	6,492	5,755	5,622	5,622	5,582
2045	2098	8,585	7,534	6,673	6,513	6,513	6,464
2046	2691	11,571	10,487	9,550	9,374	9,373	9,320
2047	2308	9,795	8,754	7,915	7,758	7,758	7,710
2048	1947	8,204	7,186	6,409	6,266	6,266	6,223
2049	1919	7,855	6,841	6,048	5,903	5,902	5,859
2050	2561	10,574	9,489	8,542	8,362	8,361	8,307
2051	1434	5,629	4,660	3,985	3,861	3,861	3,824
2052	1200	4,323	3,386	2,752	2,643	2,643	2,610
2053	1151	4,411	3,486	2,891	2,790	2,790	2,760

2054	1871	7,562	6,551	5,765	5,621	5,621	5,578
2055	1578	6,254	5,285	4,609	4,485	4,485	4,448
2056	2085	8,212	7,167	6,282	6,119	6,119	6,069
2057	1152	4,087	3,157	2,565	2,460	2,460	2,429
2058	1470	5,663	4,701	4,002	3,881	3,881	3,845
2059	1966	7,780	6,740	5,875	5,717	5,717	5,669
2060	1207	4,598	3,660	3,062	2,961	2,960	2,930
2061	2090	8,472	7,417	6,523	6,361	6,360	6,312
2062	1557	6,059	5,080	4,383	4,256	4,256	4,218
2063	1468	6,294	5,349	4,745	4,638	4,637	4,605
2064	1397	5,386	4,420	3,753	3,639	3,638	3,604
2065	1714	6,625	5,622	4,858	4,723	4,722	4,682
2066	987,4	3,677	2,779	2,283	2,196	2,196	2,171
2067	1621	6,050	5,079	4,361	4,235	4,234	4,197
2068	2211	9,088	8,034	7,166	7,004	7,004	6,955
2069	2356	9,691	8,656	7,817	7,661	7,661	7,614
2070	1353	5,492	4,569	3,993	3,893	3,893	3,863
2071	2127	8,970	7,937	7,109	6,953	6,953	6,906
2072	2154	9,344	8,317	7,513	7,364	7,364	7,319
2073	1539	6,470	5,528	4,920	4,810	4,810	4,777
2074	995,1	3,830	2,935	2,424	2,336	2,336	2,310
2075	2338	9,831	8,793	7,913	7,752	7,751	7,703
2076	3071	12,978	11,896	10,949	10,769	10,769	10,715
2077	1791	7,173	6,182	5,460	5,327	5,327	5,287
2078	1831	7,264	6,281	5,569	5,441	5,441	5,403
2079	1450	5,545	4,575	3,890	3,770	3,770	3,734
2080	1111	4,332	3,412	2,851	2,755	2,755	2,726
2081	1857	7,607	6,625	5,910	5,779	5,778	5,739

2082	1056	4,281	3,394	2,918	2,840	2,840	2,817
2083	1263	5,441	4,514	3,954	3,857	3,857	3,828
2084	1929	8,101	7,082	6,269	6,124	6,124	6,081
2085	1507	5,744	4,765	4,047	3,922	3,922	3,885
2086	1943	7,531	6,500	5,650	5,496	5,495	5,449
2087	1898	7,924	6,920	6,158	6,020	6,020	5,978
2088	2211	9,081	8,019	7,132	6,967	6,966	6,917
2089	2532	10,697	9,650	8,779	8,616	8,616	8,567
2090	2074	8,712	7,707	6,955	6,814	6,814	6,772
2091	1942	8,221	7,214	6,445	6,307	6,306	6,265
2092	2485	10,585	9,510	8,585	8,411	8,411	8,359
2093	1739	6,782	5,774	5,004	4,862	4,862	4,819
2094	2205	9,239	8,183	7,320	7,158	7,158	7,109
2095	1804	6,921	5,930	5,181	5,048	5,047	5,007
2096	2324	9,240	8,218	7,381	7,233	7,232	7,188
2097	2507	10,384	9,345	8,483	8,324	8,324	8,276
2098	1729	6,842	5,846	5,092	4,953	4,953	4,911
2099	1421	5,314	4,369	3,717	3,604	3,603	3,570
Média	1728,14	6,95	5,96	5,24	5,11	5,11	5,07
Mínima	509,60	2,09	1,27	0,94	0,90	0,90	0,88
Máxima	3071,00	12,98	11,90	10,95	10,77	10,77	10,71