

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

CLÉBER HENRIQUE DE ARAÚJO GAMA

**PREVISÃO OPERACIONAL DE VAZÕES BASEADA EM MODELO
HIDROLÓGICO CONCENTRADO, ASSIMILAÇÃO DE DADOS E PREVISÕES
METEOROLÓGICAS**

PORTO ALEGRE

2019

CLÉBER HENRIQUE DE ARAÚJO GAMA

**PREVISÃO OPERACIONAL DE VAZÕES BASEADA EM MODELO
HIDROLÓGICO CONCENTRADO, ASSIMILAÇÃO DE DADOS E PREVISÕES
METEOROLÓGICAS**

Dissertação submetida ao programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito para obtenção do título de Mestre em Recursos Hídricos e Saneamento Ambiental.

Orientador: Rodrigo C. D. de Paiva

PORTO ALEGRE

2019

CIP - Catalogação na Publicação

Gama, Cléber
PREVISÃO OPERACIONAL DE VAZÕES BASEADA EM MODELO
HIDROLÓGICO CONCENTRADO, ASSIMILAÇÃO DE DADOS E
PREVISÕES METEOROLÓGICAS / Cléber Gama. -- 2019.
95 f.
Orientador: Rodrigo Paiva.

Dissertação (Mestrado) -- 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, 2019.

1. Previsão Hidrológica. 2. Assimilação de dados.
3. Ensemble Kalman Filter (EnKF). 4. Modelo
hidrológico concentrado. 5. SOPREVA. I. Paiva,
Rodrigo, orient. II. Título.

CLÉBER HENRIQUE DE ARAÚJO GAMA

**PREVISÃO OPERACIONAL DE VAZÕES BASEADA EM MODELO
HIDROLÓGICO CONCENTRADO, ASSIMILAÇÃO DE DADOS E PREVISÕES
METEOROLÓGICAS**

Dissertação submetida ao programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito para obtenção do título de Mestre em Recursos Hídricos e Saneamento Ambiental.

Aprovado em: Porto Alegre, 11 de março de 2019.

Prof. Dr. Rodrigo Cauduro Dias de Paiva – IPH/UFRGS
Orientador

Prof. Dr. Walter Collischonn – IPH/UFRGS
Examinador

Prof. Dr. Juan Martín Bravo – IPH/UFRGS
Examinador

Dr. Conrado de Moraes Rudorff
Examinador (Membro externo)

AGRADECIMENTOS

Este trabalho está longe de ser um resultado de esforço individual e não poderia estar sendo concluído sem o esforço e contribuição de várias outras pessoas e instituições que estiveram ao meu lado e, assim, não poderia deixar de agradecer:

Ao professor Rodrigo Paiva, pela orientação, excelentes ensinamentos, amizade construída durante este período e, sobretudo, pelo exemplo de pensamento crítico e percepção do que é trabalhar com ciência.

Ao professor Walter Collischonn, por todos os ensinamentos de hidrologia e pelo grande incentivo e entusiasmo a este trabalho, sem o qual talvez não conseguiria ter despertado o interesse e a satisfação que ao fim disponho.

Ao professor Juan Martín e Dr. Conrado Rudorff, pelo aceite em participarem da banca avaliadora e pelas contribuições que constroem este trabalho e que, com certeza, serão também úteis durante toda a minha vida acadêmica à frente.

Aos amigos e colegas do grupo de pesquisa Hidrologia de Grande Escala (HGE), pela companhia e parceria durante todo o mestrado. Em especial, aos amigos João Paulo, Ayan Fleischmann, Hugo Fagundes, Sly Wongchuig e Aline Meyer, aos quais devo grande parte do aprendizado gerado por discussões construtivas, apoio em momentos difíceis e também as diversas oportunidades de descontração e felicidade, representadas sempre por boas risadas.

Aos amigos e colegas de turma, em especial Fran Vanelli, Hugo Cunha, Guilherme Censi, Juliana Andrade e Erik Quedi, pelo apoio com que juntos enfrentamos os momentos complicados e pela satisfação com que compartilhamos muito mais momentos de alegria.

Aos amigos Danielle Silva (Pariconha), Benício Monte e Thiago Tavares, pela companhia e apoio que tornaram muito mais agradável a vivência longe de casa.

Ao Matheus Tavares, um amigo que este mestrado me forneceu, que esteve comigo em todas as etapas deste trabalho e mestrado, e que com muita paciência e empenho aguentou dividir apartamento e juntos enfrentamos os difíceis momentos feedados de descontração (que deveriam ser fáceis).

À amiga Karla Julliana (Kaju), que me ajudou a enfrentar alguns dos momentos difíceis desta etapa e, através de ótimas conversas, risadas e lamentações, me ajudou na percepção de objetivos e prioridades.

Aos amigos e professores Christopher Freire e Vladimir Caramori, pelos incentivos a ingressar no IPH, ensinamentos e pelas boas reflexões que foram essenciais na minha formação.

Aos amigos Laís Almeida, Wallisson Carvalho e Yan Machado, que mesmo à distância contribuíram com discussões interessantes e também forneceram o suporte necessário para enfrentar o começo de uma nova etapa em minha vida.

Ao meu grande amigo Felipe Colombelli, que inesperadamente transformou qualquer expectativa criada sobre morar em Porto Alegre, me incentivou e motivou em todas as pequenas etapas desse mestrado e, mais importante, com apoio constante e através de longas e aleatórias reflexões, contribuiu à aquisição/construção de uma nova e valiosa perspectiva de mundo e objetivos. Sem dúvidas, se chego ao fim desta etapa de vida como uma pessoa melhor e com a mente mais clara pelo perfeito fato de procurar dúvidas, devo a ti, Felipe.

Aos meus familiares, em especial aos meus pais, Alania e Cléber, e irmã, Gabriella, que sempre me forneceram o suporte e base necessários e fundamentais para avançar em cada etapa da minha vida e que sem eles, com certeza, a conclusão desta outra etapa não estaria sendo possível.

Ao meu avô Climério, ao qual também dedico este trabalho, por todo o incentivo e suporte que tornaram possível o início e sucesso do desejo de continuar progredindo.

Por fim, agradeço à UFRGS e ao IPH pelo acolhimento e disposição de toda a estrutura e recursos necessários para a realização deste trabalho e ao CNPq pelo financiamento da bolsa de mestrado.

RESUMO

A previsão de vazões auxilia na tomada de decisões para questões de segurança e gestão dos recursos hídricos. A composição metodológica de um sistema de previsão pode ser diversa. Contudo, ao considerar-se as técnicas mais avançadas no campo da previsão hidrológica, o resultado, geralmente, se refere a metodologias de difícil implantação. Por outro lado, em termos de aplicações práticas, no Brasil são adotadas metodologias simples de previsão devido à dificuldade técnica para implantação e operação do sistema. Neste contexto, este trabalho visa propor um sistema de previsão de vazões (SOPREVA) que utiliza técnicas avançadas, como a assimilação de dados (AD) e previsão por conjunto, mas de fácil implantação e utilização. É utilizada a técnica de assimilação de dados *Ensemble Kalman Filter – EnKF* – para correção do estado do modelo através da atualização das variáveis de estado. O modelo hidrológico utilizado é um modelo concentrado, cujo balanço hídrico é baseado no modelo MGB-IPH. São avaliados aspectos da inserção de uma técnica avançada de assimilação de dados em um modelo hidrológico concentrado e então avaliado o desempenho do sistema de previsão proposto para bacias hidrográficas com características físicas distintas. A técnica de assimilação de dados melhorou o desempenho do sistema para todas as bacias de estudo avaliadas, em especial nas primeiras horas do horizonte de previsão. Nas análises utilizando chuva real, as estimativas com AD foram melhores até o quinto dia do horizonte de previsão. Para algumas das bacias, a performance do sistema pôde ser considerável equiparável a de metodologias mais complexas (Rede Neural Artificial e Modelo Distribuído) em eventos específicos e previsões de até dois dias. As previsões utilizando dados de estimativas de precipitação por modelo meteorológico (*Global Ensemble Forecast System - GEFS*) apresentaram desempenho bastante próximo do obtido com chuva real para o primeiro dia do horizonte de previsão. Contudo, o desempenho passa a ser consideravelmente inferior a partir do terceiro dia de previsão. É indicado o potencial de utilização do sistema com utilização na previsão por conjunto de eventos. Ao fim deste trabalho, o SOPREVA apresenta-se como uma ferramenta alternativa para a previsão de vazões, sobretudo sobre sua facilidade de implementação e desempenho equiparável a outros sistemas. Tal simplicidade de implementação também aponta o Sistema proposto como uma ferramenta versátil para outras investigações hidrológicas e de assimilação de dados.

Palavras-chaves: Previsão Hidrológica, Assimilação de dados, SOPREVA, EnKF.

ABSTRACT

The flow forecasting assists in decision making for safety and water resource management issues. The methodological composition of a forecasting system may be diverse. However, when considering the most advanced techniques in the field of hydrological forecasting, the result usually refers to methodologies difficult to implement. On the other hand, in terms of practical applications, in Brazil simple methodologies of forecasting are adopted due to the technical difficulty for implantation and operation of the system. In this context, this work aims to propose a flow forecasting system (SOPREVA) that uses advanced techniques, such as data assimilation (AD) and ensemble forecasting, but easy to implement and use. The technique Ensemble Kalman Filter (EnKF) is used to correct the state of the model by updating the state variables. The hydrological model used is a lumped model, whose water balance is based on the MGB-IPH model. Aspects of the insertion of an advanced data assimilation technique in a lumped hydrological model are evaluated and the performance of the proposed forecast system for watersheds with different physical characteristics is evaluated. The data assimilation technique improved the performance of the system for all study basins evaluated, especially in the first few hours of the forecast horizon. In the analyzes using real rain, the estimates with AD were better until the fifth day of the forecast horizon. For some of the basins, the performance of the system could be considerable comparable to that of more complex methodologies (Artificial Neural Network and Distributed Model) in specific events and forecasts of up to two days. The forecasts using precipitation estimates by the Global Ensemble Forecast System (GEFS) presented a performance very close to that obtained with real rain for the first day of the forecast horizon. However, the performance becomes considerably lower from the third day of forecast. It indicates the potential of use of the system with use in the forecast by set of events. At the end of this work, SOPREVA presents itself as an alternative tool for the prediction of flows, mainly on its ease of implementation and performance comparable to other systems. Such simplicity of implementation also points to the proposed system as a versatile tool for other hydrological and data assimilation investigations

Keywords: Flow Forecast, Data Assimilation, Ensemble Kalman Filter

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxograma de funcionamento do algoritmo NSGA-II.....	20
Figura 2 – Fluxograma de abordagens de aplicação da assimilação de dados na previsão hidrológica.....	22
Figura 3 – Hidrograma ilustrativo do processo de previsão de vazão com assimilação de dados. Em verde é apresentado o hidrograma verdadeiro; em azul é representado a estimativa de um modelo hidrológico; em vermelho os dados observados e em preto as previsões corrigidas com a técnica de assimilação de dados.	22
Figura 4 – Representação dos métodos de assimilação de dados sequencial e suavizado.	23
Figura 5 - Fluxograma representativo do sistema de previsão de vazões proposto neste trabalho.	24
Figura 6 – Esquema geral do modelo hidrológico concentrado utilizado.	25
Figura 7 - Ilustração de etapas da aplicação do EnKF ao modelo hidrológico concentrado.	30
Figura 8 - Fluxograma de metodologia do trabalho para aplicação dos experimentos.	32
Figura 9 - Localização no território brasileiro dos postos fluviométricos utilizados como exutórios das bacias.....	33
Figura 10 – Séries pluviométricas horárias (mm/h) das áreas de estudo, disponibilizadas pela Agência Nacional de Águas.	37
Figura 11 – Alteração percentual das variáveis de estado pela AD para a bacia UHE Campos Novos.....	46
Figura 12 – Análise de sensibilidade das estimativas de erros das variáveis de estado em UHE Campos Novos	47
Figura 13 - Análise de sensibilidade das estimativas de erros das variáveis de estado em PCH João de Deus	48
Figura 14 - Análise de sensibilidade das estimativas de erros das variáveis de estado em Passo do Mendonça.....	49
Figura 15 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Passo do Mendonça.....	50
Figura 16 - Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Fazenda Boa Fortuna.	51

Figura 17 - Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto UHE Peixe Angical.....	51
Figura 18 – Ajuste da relação entre o tempo de simulação em função do número de membros do Ensemble e extensão da série simulada.....	52
Figura 19 – Comparativo entre desempenho das previsões com e sem assimilação de dados, avaliados através do coeficiente de Nash-Sutcliffe.	53
Figura 20 - Comparativo entre desempenho das previsões com e sem assimilação de dados, com ponderação do tempo de pico de cada bacia.....	54
Figura 21 – Comparativo entre desempenho das previsões com e sem assimilação de dados, avaliados através do Coeficiente de Persistência (<i>CP</i>).	54
Figura 22 - Correlações de Spearman entre desempenho nas previsões e características das bacias.	58
Figura 23 – a) Desempenho nas previsões com horizonte até 48h para a bacia de Guajuvira a partir do SOPREVA (em azul) e de RNA (em vermelho); b) Hidrogramas para vazões previstas com 5h de antecedência.	60
Figura 24 – Desempenho de previsões com utilização de estimativas de precipitação: do GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul).	61
Figura 25 - Desempenho de previsões para vazões acima da Q50. Comparativo entre GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul).	62
Figura 26 - Comparativo entre GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul) para eventos às 00h e com horizonte de até 168h.	63
Figura 27 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Fazenda Boa Fortuna. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	63
Figura 28 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Fazenda Boa Fortuna. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	64
Figura 29 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Guaporé. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	64

Figura 30 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Guaporé. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	65
Figura 31 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Guajuvira. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	65
Figura 32 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Guajuvira. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	66
Figura 33 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia UHE Campos Novos. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	66
Figura 34 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia UHE Campos Novos. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	67
Figura 35 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Passo do Mendonça. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	67
Figura 36 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Passo do Mendonça. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.	68
Figura 37 – Previsão por conjunto em evento na bacia UHE Campos Novos em momento logo após início da ascensão do hidrograma.	69
Figura 38 - Previsão por conjunto em evento na bacia Guaporé em momento próximo ao pico do hidrograma do evento, com previsão para recessão.	69
Figura 39 - Previsão por conjunto em evento na bacia UHE Campos Novos em momento de ascensão do hidrograma.	70
Figura 40 - Previsão por conjunto em evento na bacia PCH João de Deus em momento de ascensão do hidrograma.	70

LISTA DE TABELAS

Tabela 1 - Informações sobre as séries de dados observados de precipitação e vazão.	34
Tabela 2 – Características das bacias selecionadas para estudo	36
Tabela 3 - Parâmetros calibráveis do modelo para as seis bacias de estudo.	43
Tabela 4 – Medidas de desempenho da calibração manual do modelo hidrológico concentrado.	44
Tabela 5 - Comparativo entre desempenho na calibração com o SOPREVA e com o MGB/IPH para algumas bacias analisadas.	44
Tabela 6 – Estimativa dos erros das variáveis de estado do modelo para as diferentes bacias.	46
Tabela 7 – Número de membros do Ensemble definidos para cada bacia.	52
Tabela 8 – Comparativo entre desempenho de previsões com e sem assimilação de dados.	55
Tabela 9 – Desempenho do SOPREVA para previsões utilizando dados diários em cinco bacias	55
Tabela 10 – Desempenho das previsões por conjunto medido através do RMSE entre a média dos membros e valores observados para horizontes de até 24 e para todo o período de previsão de 168h. .	71

SUMÁRIO

1. Introdução.....	9
2. Objetivos.....	11
2.1. Objetivo Geral.....	11
2.2. Objetivos específicos.....	11
3. Revisão bibliográfica	12
3.1. Previsão Hidrológica	12
3.1.1. Previsões por Ensemble.....	13
3.2. Modelagem Hidrológica na previsão de vazões.....	16
3.3. Calibração de parâmetros de modelos hidrológicos.....	17
3.3.1.1. SCE-UA.....	18
3.3.1.2. NSGA-II	19
3.4. Assimilação de dados	21
4. Metodologia.....	23
4.1. Sopreva – Sistema Operacional de Previsão de Vazões.....	23
4.1.1. Modelo Hidrológico	24
4.1.1.1. Calibração de parâmetros	27
4.1.2. Assimilação de dados	28
4.1.2.1. EnKF – Ensemble Kalman Filter	28
4.2. Avaliação do sistema SOPREVA – Áreas de estudo e descrição dos Experimentos ..	31
4.2.1. Áreas de estudo e dados de entrada do Sistema.....	32
4.2.1.1. Caracterização das áreas de estudo	34
4.2.2. Estimativas dos erros das variáveis de estado.....	38
4.2.3. Definição do número de membros do Ensemble	38
4.2.4. Previsão de vazões com precipitações observadas (chuva real)	39
4.2.5. Previsão de vazões com previsão meteorológica	40
4.2.5.1. GEFS	40

4.2.5.1.	Previsão para período contínuo	41
4.2.5.2.	Previsão em eventos selecionados.....	42
4.3.	Avaliação de desempenhos	42
5.	Resultados.....	43
5.1.	Calibração do Modelo Hidrológico	43
5.2.	Estimativa dos erros das variáveis de estado	45
5.3.	Definição do número de membros do Ensemble	50
5.4.	Previsões com chuva real.....	52
5.5.	Previsões com estimativas de chuva do GEFS	60
5.5.1.	Previsão operacional ao longo da série temporal	60
5.5.2.	Previsão em eventos selecionados.....	68
6.	Conclusões e Recomendações	72
7.	Referências bibliográficas	74
8.	Apêndice.....	79
8.1.	Estimativa dos erros das variáveis de estado – Análise de sensibilidade	79
8.2.	Definição do número de membros do Ensemble	83
8.3.	hidrogramas de previsões baseadas em Chuva real, GEFS e Chuva real sem AD	88

1. INTRODUÇÃO

Sistemas de previsão de vazões são ferramentas de grande auxílio na prevenção de desastres decorrentes de eventos extremos, cheias ou secas, e também para operação adequada de reservatórios, sejam estes voltados para geração de energia ou outros usos.

Para devida efetividade desses sistemas, todavia, é necessário i) o adequado monitoramento das variáveis que compõe o modelo hidrológico; ii) boas estimativas de previsão da precipitação e; iii) um modelo capaz de representar os processos hidrológicos ocorrentes na bacia, para melhores estimativas na relação chuva-vazão (Chen et al., 2013).

Tratando de sistemas operacionais, a composição metodológica é diversa. Podendo ser baseados em

No Brasil, quando se trata de previsões para composição de um sistema de alerta, principalmente, predomina a utilização de modelos estatísticos ou de regressão cota a cota, com utilização das observações a montante para previsão nas localidades a jusante.

Para barramentos, muitos baseiam sua operação em sistemas de previsão com baixo embasamento físico. Um estudo realizado pelo Operador Nacional do Sistema (ONS) em 2007 (Guilhon et al., 2007), comparou as estimativas de um destes sistemas com diversas outras metodologias de previsão e constatou que diversos outros métodos, com implementação específica para uma localidade, apresentariam melhor desempenho do que o modelo estatístico até então utilizado (Fan et al., 2016). Desde então, alguns sistemas operacionais alternativos com modelos hidrológicos de embasamento físico têm sido propostos e aplicados (e.g. Collischonn et al., 2007 e Fan et al., 2014).

O desempenho destes sistemas, contudo, depende diretamente i) da qualidade das estimativas de precipitações forçantes futuras e ii) na simulação do armazenamento da bacia no início da previsão (Lettenmaier e Wood, 1993).

Sobre o primeiro ponto, modelos meteorológicos que fornecem previsões de precipitação melhoraram seu desempenho na geração de estimativas e tornou-se também possível fazer previsões por ensemble, permitindo a consideração de incerteza nos resultados.

Do último ponto, a Assimilação de Dados (AD) tem sido cada vez mais aplicada para melhoria da performance de sistemas de previsão. Dentre as técnicas de assimilação comumente aplicadas está o Filtro de Kalman por Conjunto (Evensen, 2003 e Evensen, 2004). O conceito básico por trás da AD consiste na quantificação de erros do modelo hidrológico e das observações para uma posterior atualização otimizada das variáveis de estado do modelo.

A eficiência de técnicas de assimilação de dados na previsão de vazões ou eventos extremos é vastamente comprovada na literatura, incluindo também a possibilidade de consideração de informações oriundas de sensoriamento remoto (e.g. Chen et al., 2013; Paiva et al., 2013; Clark et al., 2008; Meller et al., 2012; Paz et al., 2007).

Apesar de todos estes avanços mencionados, sistemas compostos por um modelo hidrológico distribuído, de base física, com uma técnica de assimilação de dados e previsão de precipitações por conjunto podem ser complexos e dependem de um grande esforço para montagem e operação, tornando-se em muitos casos inviável a operacionalização e resultando na escolha pela simplicidade de modelos mencionados anteriormente.

Neste sentido, se faz necessário investigar a performance de técnicas mais simplificadas, que possam ser operacionalizadas com maior facilidade, mas que tirem proveito dos mais recentes avanços científicos.

Ainda é muito limitado, por exemplo, o número de trabalhos que avaliam modelos hidrológicos concentrados com aplicação de técnicas de AD com foco na previsão de vazões (Chen et al., 2013), a exemplo dos trabalhos de Weerts e Serafy (2006) e de Chen et al. (2013).

Por outro lado, Vrugt et al. (2005) já relatavam a capacidade de um modelo hidrológico concentrado, acoplado com um modelo de assimilação de dados, em oferecer estimativas de vazões com performance comparável a modelos sofisticados de redes neurais. E Carpenter e Georgakakos (2006) discutem as implicações na utilização de modelos hidrológicos concentrados ou distribuídos para a previsão de vazões, diante de tantas outras incertezas.

O interesse por sistemas mais simples, com utilização de um modelo concentrado para geração de vazões, apoia-se, principalmente, na facilidade de implementação e, portanto, possibilidade de implantação rápida de um sistema de previsão para determinada localidade.

Neste cenário, este trabalho visa propor um sistema operacional de previsão de vazões, simplificado e contribuir com a verificação da aplicabilidade e eficiência de uma técnica de assimilação de dados em um modelo hidrológico concentrado.

Ao fim do trabalho, busca-se responder questões quanto à aplicabilidade da composição do sistema proposto em bacias hidrográficas de características distintas, enquadrando o desempenho das estimativas geradas frente a outras fontes de previsão; contribuir com informações sobre a aplicação de uma técnica de assimilação de dados para previsão hidrológica utilizando um modelo hidrológico concentrado; indicar configurações do sistema e da técnica de assimilação de dados que otimizam as previsões geradas e; propor um sistema operacional de previsão de vazões com fácil e rápida implantação.

2. OBJETIVOS

2.1. OBJETIVO GERAL

Propor e avaliar um sistema simplificado de previsão de vazões, baseado em técnicas avançadas de modelagem de base física, assimilação de dados e previsão meteorológica, porém de fácil operacionalização.

2.2. OBJETIVOS ESPECÍFICOS

- Desenvolver um sistema de previsão de vazões composto por modelo hidrológico concentrado e com utilização de uma técnica de assimilação de dados (EnKF) para correção do estado do modelo nos instantes de previsão;
- Avaliar a acurácia do sistema de previsão de vazões proposto para diversas bacias brasileiras, com características distintas, verificando sua aplicabilidade;
- Analisar as relações entre as características das bacias e o desempenho do Sistema, a discutir sob quais ocasiões torna-se aplicável um modelo hidrológico concentrado com utilização de uma técnica de assimilação de dados em um sistema de previsão;
- Analisar as estimativas de erros das diferentes variáveis de estado do modelo e parâmetros de assimilação e suas influências no desempenho das previsões;
- Avaliar a performance do Sistema com utilização de estimativas de um modelo meteorológico como fonte de informação de precipitações previstas;
- Avaliar o desempenho do sistema na previsão de eventos hidrológicos a partir da previsão por conjuntos, baseada nas estimativas de membros de um modelo meteorológico.

3. REVISÃO BIBLIOGRÁFICA

3.1. PREVISÃO HIDROLÓGICA

Previsão hidrológica é a estimativa de uma ou mais variáveis hidrológicas para um passo de tempo futuro baseada em informações observadas até o presente (Lettenmaier e Wood, 1993). As variáveis comumente de interesse em sistemas de previsão hidrológica são vazões, níveis ou umidade do solo.

Modelos de previsão hidrológica podem oferecer grande auxílio em um sistema de alerta de inundações, na tomada de decisão para operações de barragens ou mesmo para determinação de níveis de navegação em uma região (Tucci, 2005).

As escalas temporais e espaciais em que são aplicadas as previsões interferem diretamente nas aplicações e funcionalidades de um sistema de previsão. Neste contexto, quanto à escala temporal, as previsões podem ser de curto prazo, em tempo real, ou previsões de longo prazo, sazonais. Os limites entre estas classes não são claros e dependem diretamente da aplicação, com base no interesse e no tempo de resposta da bacia hidrográfica.

Previsões sazonais podem ser utilizados para a previsão de estiagens, manejo dos recursos hídricos, previsão de degelo anual e outros processos hidrológicos decorrentes de processos mensais ou anuais.

A previsão de curto prazo é realizada para antecedência de horas ou dias. Este tipo de previsão é aplicado, por exemplo, para alerta de inundações e outros desastres ou operação de obras hidráulicas, como barramentos e sistemas de comportas. Segundo Tucci et al. (2003), para este tipo de previsão podem ser aplicados modelos de propagação de onda de cheia ou modelos do tipo chuva-vazão.

Quanto às escalas espaciais, atualmente já existem sistemas de previsões interessados na representação regional ou global dos processos hidrológicos. O *The Global Flood Awareness System* (GloFAS), desenvolvido em conjunto pela *European Commission* e pelo *European Centre for Medium-Range Weather Forecasts* (ECMWF), por exemplo, é uma ferramenta que realiza simulações diárias de vazões e fornece previsão de cheias com um prazo de duas semanas, para todo o globo terrestre (Hirpa et al., 2016). O GloFAS consiste em simulações hidrológicas distribuídas decorrentes de previsões meteorológicas com cobertura global. As previsões de vazões são então comparadas estatisticamente com simulações climatológicas para detectar excedentes probabilísticos de limiares de alerta (Alfieri et al., 2013).

Sistemas de previsão de grande cobertura espacial, como o GloFAS, embora sejam bastante úteis para estudos hidrológicos globais ou antecipação de grandes eventos hidrológicos, podem, contudo, não apresentar a performance desejada para as estimativas em locais específicos e com a discretização requerida a algumas aplicações (e.g. Moraes et al., 2017). Desta forma, sistemas mais simples e especificamente calibrados e desenvolvidos para uma região podem apresentar melhores desempenhos em suas estimativas.

Independentemente das escalas temporais e espaciais, sistemas baseados na transformação chuva-vazão necessitam como entrada dados observados de precipitações, que serão então processados pelo modelo para simular adequadamente os processos hidrológicos na bacia. Tal modelo deve então ser calibrado para representação das características específicas da bacia hidrográfica. Contudo, ainda que o modelo apresente bom desempenho de simulação, suas estimativas apresentarão diferenças às observações reais, decorrentes dos erros do modelo.

Em um ambiente de previsões operacionais em tempo real, onde as simulações são feitas no tempo presente com informações recentes, o desempenho do sistema está diretamente ligado à qualidade das estimativas de precipitações futuras e às incertezas nas condições iniciais do modelo no momento da previsão.

No que se refere às estimativas da forçante precipitação, modelos de previsão climática estão evoluindo e podem ser utilizados como fonte de informação para o sistema de previsão hidrológica. Quanto às incertezas nas condições iniciais, há grandes esforços para implementação de técnicas de utilização de dados observados recentes para inicializar os estados nos modelos hidrológicos, processo denominado assimilação de dados. Estes dois tópicos são então discutidos nas seções seguintes.

3.1.1. Previsões por Ensemble

Um dos principais problemas em previsões hidrológicas baseadas em informações de modelos meteorológicos para estimativa de precipitações é a grande incerteza existente nas previsões do tempo, onde os resultados podem variar bastante com a realização das previsões em pequenas horas de diferenças (Cloke e Pappenberger, 2009; Cuo *et al.*, 2011).

Isto acontece por que a solução do sistema de equações que descrevem os movimentos atmosféricos dentro de modelos meteorológicos de previsão do tempo é muito sensível às condições iniciais fornecidas no começo dos cálculos de integração (Cuo *et al.*, 2011).

Desta forma, melhorar a capacidade dos modelos de previsão de tempo na descrição dos processos por si só não é suficiente para obter boas previsões, e que é necessário levar em conta

também toda a incerteza associada com as observações utilizadas na geração da condição inicial da simulação (Buizza *et al.*, 1999).

Para contornar tal problema, surgiu o conceito de previsão por conjunto, ou por *Ensemble*, que procura explorar as incertezas associadas às condições iniciais e/ou deficiências dos modelos numéricos de previsão de tempo.

Em previsões por conjunto são geradas várias previsões, denominadas "membros", onde cada um dos membros do conjunto representa uma possível trajetória dos processos atmosféricos ao longo do horizonte de previsão.

A geração destes membros pode ser feita a partir de i) diferentes modelos meteorológicos; ii) diferentes parametrizações ou; iii) de diferentes condições iniciais de um único modelo. A previsão probabilística ou por conjunto tem sido usada operacionalmente na previsão meteorológica desde a década de 1990 (Buizza *et al.*, 1999).

As previsões por conjunto, ao contrário das previsões determinísticas, permitem uma interpretação mais ampla dos resultados previstos. Com elas teoricamente é possível fazer inferências sobre quais são as trajetórias mais prováveis da variável a partir da maior concentração dos membros, é possível estimar a probabilidade de ocorrência de eventos de interesse hidrológico (como a chuva total acima de um valor de referência), e é possível verificar qual é a predictabilidade da atmosfera a partir do espalhamento dos membros (Buizza, 2008).

Basicamente o que se busca com as previsões por ensemble é que a inclusão das incertezas na geração de resultados permita auxiliar e embasar os diferentes processos de tomada de decisão.

Internacionalmente, um dos pioneiros a desenvolver um sistema de previsão por ensemble, ou *Ensemble Prediction System* (EPS), foi o ECMWF (European Centre for Medium-Range Weather Forecasts), operacional desde 1992 (Molteni *et al.*, 1996).

No Brasil, o Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE) opera desde 2001 um sistema de previsão global do tempo por ensemble.

Um outro EPS operacional atualmente e com aplicações em estudo de previsões hidrológicas (e.g. Fan *et al.* 2014; Fan *et al.* 2016) é o mantido pelo *National Center for Environmental Prediction* (NCEP) do *National Oceanic and Atmospheric Administration* (NOAA) dos Estados Unidos (Hamill *et al.*, 2013). O nome do modelo é GEFS (*Global*

Ensemble Forecasting System). Maiores informações sobre este modelo serão apresentadas nas sessões seguintes deste trabalho.

A configuração do GEFS foi variada ao longo dos anos e a partir de 2013 passou-se a emitir também previsões baseadas em uma nova configuração do modelo chamado de GEFS v2 (Hamill *et al.*, 2013) Esta nova versão possui 10 membros no conjunto, mais a previsão controle.

Motivado pelo sucesso da utilização de EPSs na meteorologia, ao longo dos últimos 15 anos começaram esforços de incorporação de ensembles nas metodologias de previsão de vazão, dando origem aos chamados sistemas de previsão hidrológica por ensemble, ou *Hydrologic Ensemble Prediction Systems* (HEPSs) (Cloke e Pappenberger, 2009).

A estratégia adotada é reconhecer a incapacidade de prever com exatidão a quantidade de chuva que irá atingir uma bacia hidrográfica (e outras variáveis, como temperatura), e adotar uma postura de quantificação da incerteza da previsão através de um conjunto de cenários futuros para a vazão (Pappenberger e Brown, 2013).

Com isso, espera-se estar abrangendo nas previsões um maior número de fontes de erros. Embora, reconhecidamente a incerteza da natureza caótica das previsões meteorológicas seja a mais importante de todas (Pappenberger., 2009; Cuo *et al.*, 2011).

Em contexto brasileiro, um dos trabalhos pioneiros abordando o uso de ensembles na previsão hidrológica foi o de Calvetti (2011), no qual foram avaliadas as previsões para a bacia do Rio Iguaçu (24.000 km²). Neste caso, o autor utilizou o modelo hidrológico TopModel e o modelo atmosférico WRF (Weather and Research Forecasting).

Posteriormente, Meller (2012), Collischonn *et al.* (2013), e Meller *et al.* (2014) apresentam resultados de análises de previsão de vazão por conjunto de curto prazo tendo como estudo de caso uma bacia de médio porte localizada na região sudeste do Brasil, a bacia do Rio Paraopeba (12.150 km²), com utilização do modelo MGB-IPH.

Fan (2015b) também utilizou o modelo MGB-IPH para realizar previsão de vazão para três bacias hidrográficas brasileiras: Alto São Francisco, Doce e Tocantins. Para isso, o modelo hidrológico foi alimentado por dados de precipitação obtidos por três sistemas de previsão meteorológica por conjunto (ECMWF-pf, GEFS e CPTEC-pf).

Siqueira (2015), também utilizou o modelo MGB-IPH para realizar previsão de cheias por conjunto na bacia do Taquari-Antas/RS. Para isso o modelo hidrológico foi acoplado a diferentes sistemas de previsão, são eles: EPS regional ETA, de curto prazo (até 72 horas), EPS

Global ECMWF de médio prazo (até 10 dias), e previsão determinística do modelo regional ETA (até 7 dias).

3.2. MODELAGEM HIDROLÓGICA NA PREVISÃO DE VAZÕES

Conforme discutido anteriormente, a forma mais comum encontrada em sistemas operacionais no Brasil de representação das relações hidrológicas para geração das previsões de vazões consiste em modelos chuva-vazão sem embasamento físico. Contudo, este cenário está sendo modificado e já há muitas iniciativas para implementação de sistemas de previsão baseado em de base física ou conceituais (Fan et al., 2016).

Tais modelos hidrológicos consistem na representação dos processos físicos encontrados na bacia hidrográfica, e suas relações, através de equações matemáticas. Para simulação, estes modelos geralmente utilizam como entrada dados de observações de algumas variáveis hidrológicas (por exemplo, chuva, vazão, umidade do solo, evapotranspiração) e, a partir de uma calibração de parâmetros das equações supracitadas, conseguem reproduzir o comportamento hidrológico de diferentes bacias, sendo capaz de fornecer diferentes informações hidrológicas.

O grande diferencial para este tipo de modelos corresponde à capacidade de representar o comportamento hidrológico da bacia através de aspectos físicos. Com isso, acredita-se que os modelos de base física são capazes de extrapolar suas simulações para além do domínio dos dados observados com maior coerência do que o conseguido por outros modelos (Tucci, 2005; Sene, 2010).

Historicamente foi associada a utilização de modelos hidrológicos do tipo concentrado a pequenas bacias e, quando tratar-se de bacias maiores, a opção deveria ser feita por modelos do tipo distribuído. Esta questão é embasada no fato de um modelo concentrado utilizar características médias da bacia para representação dos processos, enquanto que o modelo distribuído pode ser alimentado com informações distintas para uma mesma característica em regiões diferentes de uma mesma bacia (Tucci, 2005). Assim, em bacias maiores, onde geralmente é encontrado maior variabilidade de características, um modelo hidrológico concentrado não seria capaz de simular com o mesmo desempenho de um modelo distribuído.

Contudo, tratando-se de previsões hidrológicas, principalmente, é questionável as implicações de se utilizar um modelo hidrológico concentrado ou distribuído diante outras incertezas, como a estimativa meteorológica para precipitações (Carpenter e Georgakakos, 2006).

Além disso, como já mencionado, o uso de técnicas de assimilação de dados em modelos hidrológicos, para ajuste de parâmetros ou correção das variáveis de estado do modelo visando a previsão de vazões ou de eventos de cheias, tem se intensificado (e.g. Chen et al., 2013; Paiva et al., 2013; Clark et al., 2008; Meller et al., 2012; Paz et al., 2007) e, com isso, há a possibilidade de aumentar o potencial de modelos mais simples, como os do tipo concentrado, em obter melhores desempenhos nas previsões hidrológicas.

Há sistemas operacionais de previsão que utilizam modelos hidrológicos concentrados apoiados com técnicas de assimilação de dados. A capacidade de um modelo hidrológico concentrado, acoplado com um modelo de assimilação de dados, em oferecer estimativas de vazões com performance comparável a modelos sofisticados de redes neurais é relatado por Vrugt et al. (2005).

Porém, trabalhos com aplicação de técnicas de assimilação de dados, com foco na previsão de vazões, geralmente ainda utilizam modelos hidrológicos distribuídos, sendo raros aqueles que fazem uso de modelos hidrológicos concentrados ou busquem estes sistemas operacionais mais simples (Chen et al., 2013).

3.3. CALIBRAÇÃO DE PARÂMETROS DE MODELOS HIDROLÓGICOS

Uma das principais etapas da aplicação de um modelo chuva-vazão é a calibração dos parâmetros deste modelo para a localidade em estudo. De maneira geral, tal processo é realizado a partir da variação da combinação de valores dos parâmetros até um ponto satisfatório na relação entre hidrograma calculado e observado.

O processo é iterativo e o efeito da mudança dos valores dos parâmetros no desempenho do modelo é avaliado repetidamente. O critério de parada, contudo, depende do usuário do modelo, podendo ser definido pela concepção de bom desempenho a partir de i) uma avaliação visual; ii) uma avaliação quantitativa das vazões máximas e/ou mínimas ou; iii) pelo alcance de determinado valor, pré-definido, em uma função objetivo (Tucci, 2005).

Desta forma, o processo de calibração pode ser entendido como uma etapa subjetiva da modelagem, mas a melhoria da qualidade desta etapa pode ser buscada através da avaliação do ponto de parada sob critérios distintos.

Por outro lado, tratando-se de um modelo, é buscada uma boa representação, mas sabemos que nenhum modelo hidrológico, seja ele concentrado ou distribuído, será capaz de atingir uma perfeita concordância entre os valores calculados e observados. Sempre existirão erros nos valores medidos, na estrutura do modelo ou nos parâmetros calibrados que resultarão em incertezas no resultado. Por esta incerteza, é importante lembrar também que podem existir

faixas de valores dos parâmetros ou diferentes combinações de valores que geram resultados e/ou desempenhos semelhantes (Beven, 1993).

Na calibração manual é utilizada a técnica da tentativa e erro, aliada sempre à experiência anterior do usuário. Quando o usuário é inexperiente, a calibração manual pode ser extremamente demorada e pouco eficaz, muitas vezes devido a não existir um critério objetivo de parada (Sorooshian e Gupta, 1995).

Para lidar com algumas situações, por exemplo, em que o usuário tem pouca experiência ou há um grande número de pontos a serem calibrados, foram criados os métodos de calibração automática.

Alguns fatos, como i) um conjunto de parâmetros resultantes, que geraram bons valores para uma função objetivo, que pode ter valores absurdos no ponto de vista conceitual/físico; ii) perda da sensibilidade e entendimento do usuário sobre os processos hidrológicos da bacia; iii) nem sempre o tempo gasto com a calibração automática é inferior ao gasto com uma manual ou; iv) a avaliação subjetiva feita na calibração manual não pode ser representada através das funções objetivas avaliadas, levaram alguns hidrólogos a criticarem o processo automático em seu início. Contudo, com o avanço no desenvolvimento de novos algoritmos de otimização e definição de novas funções objetivo, o processo de calibração automática vem reduzindo seus pontos fracos tornando-se mais atrativo na modelagem hidrológica.

O objetivo da calibração automática, portanto, é minimizar ou maximizar o valor de uma função objetivo que mede a qualidade do ajuste dos hidrogramas (Sorooshian e Gupta, 1995). Na calibração automática multi-objetivo, o objetivo é otimizar, ao mesmo tempo, várias funções, que avaliam vários aspectos da qualidade do ajuste entre hidrogramas calculado e observado.

Entre os algoritmos de otimização global propostos recentemente destacam-se os algoritmos genéticos, que contém inspirações biológicas em suas concepções, e estão baseados no processo de evolução de uma população, sujeita a algumas regras de seleção natural, tal como ocorre com os seres vivos na natureza. Dentre estes, destacam-se os algoritmos SCE-UA (Duan et al., 1992) e o NSGA-II (Deb et al., 2002) que foram incorporados ao modelo e que estão descritos a seguir.

3.3.1.1. SCE-UA

O algoritmo SCE-UA, inicialmente descrito por Duan et al. (1992), foi criado com o objetivo de contornar o problema de métodos de calibração automática tenderem a encontrar pontos ótimos locais. O SCE-UA foi desenvolvido baseado na combinação de técnicas de busca

aleatória, algoritmos genéticos e otimização local. O nome SCE é derivado das iniciais de Shuffled Complex Evolution, o que pode ser traduzido por “Evolução de Complexos Misturados” (Diniz, 1999).

O algoritmo funciona a partir de uma população de pontos que “evolui” em direção a uma região, ou ponto, tido como o ótimo global, através de sucessivas iterações e avaliações da função objetivo pré-definida. Cada um destes pontos da população é definido por um conjunto de valores dos parâmetros e é um candidato a ser o ótimo.

Segundo seus autores, o algoritmo SCE – UA imita o processo de evolução natural. Os pontos da amostra constituem uma população de uma espécie. Esta população está dividida em diversas comunidades, que são os complexos. A cada uma das comunidades é dada a oportunidade de evoluir de forma independente, por um determinado período. Após um número de gerações, pré-determinado (β), as comunidades se encontram, são misturadas e uma nova divisão é feita. Este processo de mistura permite o compartilhamento de informações que cada comunidade adquiriu de forma independente (Sorooshian e Gupta, 1995).

Ainda na analogia biológica, cada um dos membros de uma comunidade é um candidato a participar no processo de reprodução. Um sub-complexo retirado de um complexo é como um casal biológico. A diferença é que o sub-complexo pode ter mais de 2 membros. Para garantir que o processo seja competitivo, é necessário que os melhores “pais” tenham maior probabilidade de gerar “filhos” do que os piores. Para isso, a qualidade dos “pais” e, conseqüentemente, a probabilidade de gerar “filhos”, é avaliada pelo valor da função objetivo.

Os principais pontos atrativos para implementação deste método de calibração automática é i) a simplicidade do método e código – trabalhando com apenas uma função objetivo; ii) o curto tempo de simulação e; iii) a ampla consolidação e reconhecimento da aplicação deste método em modelos hidrológicos.

3.3.1.2. NSGA-II

O algoritmo NSGA-II (*Non-dominated Sorting Genetic Algorithm II*), apresentado por Deb *et al.* (2002), é um algoritmo multiobjetivo que implementa o conceito de Dominância, ou seja, a classificação da População em *fronts*, de acordo com seu grau de dominância.

Através do critério de dominância, o algoritmo agrega o conceito de Elitismo e classifica a população total em diferentes categorias de qualidade, ao invés de tratá-las como um único grupo. Isso permite ao método a priorização daqueles indivíduos melhor classificados.

O funcionamento do NSGA-II se destaca por possuir duas etapas no processo de seleção: *Fast Non-dominated Sorting* e o *Crowding Distance*, apresentados nos tópicos seguintes. A Figura 1 apresenta um fluxograma do funcionamento do algoritmo.

Na prática, têm-se inicialmente uma população inteira ainda não classificada, que irá passar por um processo de atribuição de grau de dominância a cada indivíduo, em relação a todos os outros indivíduos da população.




Figura 1 – Fluxograma de funcionamento do algoritmo NSGA-II

Após os valores de dominância terem sido atribuídos a todos da população, esses indivíduos são classificados em *fronts* de acordo com seus valores de dominância. Os melhores indivíduos são classificados no primeiro, e os piores são classificados no último *front*.

Após todos os indivíduos estarem classificados, eles serão classificados pelo Operador de Diversidade, ou seja, o *Crowding Distance*. Esse operador ordenará cada indivíduo de acordo com a sua distância em relação aos pontos vizinhos no mesmo *front*. Quanto mais distantes desse ponto central, maior a probabilidade de serem selecionados. Assim, esse operador permite que haja um melhor espalhamento dos resultados, evitando-se aglomerações de soluções sobre um mesmo ponto.

3.3.1.2.1. *Fast Non-Dominated Sorting*

O algoritmo de seleção *Fast Non-Dominated Sorting* é executado em duas etapas, referenciadas como Processo 1 e Processo 2, a partir deste ponto

O Processo 1 analisará todos os indivíduos da População total P , comparando-os uns com os outros para classificá-los de acordo com o grau de dominância np (número de indivíduos que dominam p , em que p é um indivíduo da população P). Dessa forma se um indivíduo p é dominado por um número x de indivíduos da população total P , o seu valor correspondente de np é igual a x . Se ao final do Processo 1, o indivíduo possuir o valor de np igual a 0, significa dizer que esse indivíduo não é dominado por ninguém dentro da População Total P e que tais indivíduos, a partir do Processo 2, farão parte do primeiro *front*, no qual estão os melhores indivíduos de toda a população atual.

O Processo 2, separará cada indivíduo em diferentes categorias (*os fronts*) de acordo com os seus valores de dominância, indicados pelos seus respectivos valores de np . Cada indivíduo incluído em um dos *fronts* é retirado totalmente do contexto do sistema,

decrementando os valores de np de cada indivíduo dominado por esses. Isso repete-se até que não sobrem mais indivíduos na população restante.

3.3.1.2.2. *Crowding Distance*

O *Crowding Distance* é o Operador de Diversidade usado no NSGA II, a fim de se garantir um maior espalhamento dos resultados ao longo da região de pareto. Tal ação visa evitar a concentração de soluções em cima de um mesmo ponto ou região. Além disso, é utilizado como método de ordenação dos indivíduos dentro de um mesmo *front*.

Esta etapa utiliza como métrica a distância de cada indivíduo aos indivíduos mais próximos. Portanto, calcula a distância média entre um ponto central i selecionado dentro da população e dois pontos localizados nas extremidades do ponto central ($i-1$) e ($i+1$). A ideia é que, a partir de um ponto central, o Operador de Diversidade possa encontrar pontos extremos e priorizar os pontos mais distantes durante o processo de seleção, a fim de espalhar os resultados ao longo da região de pareto.

Ao final do *Crowding Distance*, os resultados serão ordenados dando preferência às soluções com distâncias médias maiores. O algoritmo visa encontrar soluções diversificadas e que não se encontrem concentradas em uma região limitada do gráfico, e que permita ao tomador de decisão ter uma ampla visão sobre as melhores soluções que ele poderá aplicar para gerar soluções.

3.4. ASSIMILAÇÃO DE DADOS

A técnica de assimilação de dados pode ser interpretada como uma otimização a partir da consideração das observações e respostas prévias do modelo para valores das variáveis ou parâmetros.

Inicialmente foi amplamente aplicada na área das geociências, para previsões meteorológicas e caracterização das condições atmosféricas e oceânicas, e mais recente a assimilação de dados tem tomado grandes aplicações na área de hidrologia, com destaque para sistemas de previsões (Liu e Gupta, 2007).

Em sistemas de previsão operacional a utilização de técnicas de assimilação de dados em modelos hidrológicos ou hidráulicos pode seguir quatro abordagens: i) assimilação de variáveis de estado; ii) atualização das variáveis de entrada; iii) atualização de erros ou; iv) estimativa e correção de parâmetros (Liu et al., 2012; Refsgaard, 1997). A Figura 2 apresenta um fluxograma de como cada uma das abordagens supracitada interage com o modelo e em qual etapa da previsão hidrológica é aplicada.

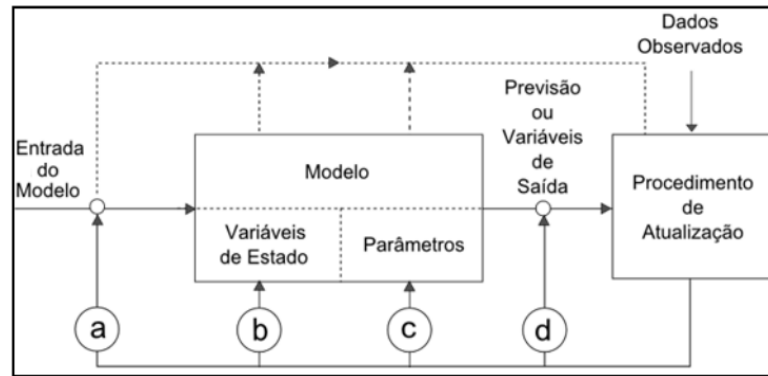


Figura 2 – Fluxograma de abordagens de aplicação da assimilação de dados na previsão hidrológica.
Fonte: Refsgaard, 1997.

No caso da assimilação de variáveis de estado, a ideia principal e objetivo da assimilação de dados é corrigir o estado inicial do modelo para o momento de previsão. Desta forma, como pode ser visualizado na Figura 3, as previsões do modelo partirão de estimativas mais próximas da realidade, diminuindo os erros já obtidos no instante de partida. O hidrograma ilustrativo apresentado demonstra que as vazões previstas pelo modelo com utilização de uma técnica de assimilação de dados (em preto), ao assimilar os dados observados (em vermelho), aproximam-se mais da série verdadeira de vazões (em verde) do que aquelas geradas pelo modelo hidrológico sem assimilar novas observações (em azul).

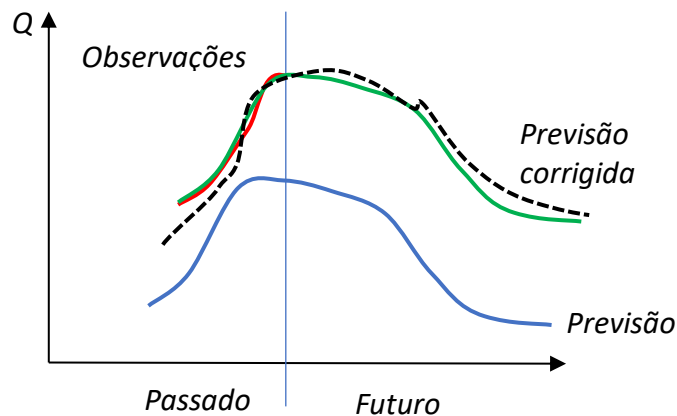


Figura 3 – Hidrograma ilustrativo do processo de previsão de vazão com assimilação de dados. Em verde é apresentado o hidrograma verdadeiro; em azul é representado a estimativa de um modelo hidrológico; em vermelho os dados observados e em preto as previsões corrigidas com a técnica de assimilação de dados.

A ideia básica, portanto, de aplicar de um método de assimilação de dados consiste em quantificar os erros do modelo hidrológico e das observações para assim atualizar as variáveis de estado do modelo com uma otimização entre modelado e observado.

Há diversos métodos de assimilar dados, que essencialmente podem ser divididos em dois tipos: sequencial e suavizado. Métodos sequenciais são aqueles em que as observações são assimiladas a cada passo de tempo, gerando melhores estimativas atuais e para futuras

previsões. Já nas técnicas de assimilação do tipo suavizada, as observações de um certo intervalo de tempo são assimiladas no modelo de uma vez, gerando uma forma mais suave de assimilação no tempo (Lahoz et al., 2010). Os dois tipos supracitados de técnicas de assimilação de dados seguem apresentados na Figura 4.




Figura 4 – Representação dos métodos de assimilação de dados sequencial e suavizado.
Fonte: Brêda, 2017.

Dentre os métodos de assimilação do tipo sequencial e aquele com mais aplicações na hidrologia encontra-se o Filtro de Kalman por Conjunto (e.g. Paiva et al., 2013; Clark et al., 2008; Vrugt et al. 2005; Dumedah e Coulibaly, 2013; Weerts e El Serafi, 2006), no qual é considerado como verdade a média do conjunto e, então, estimado o erro do modelo a partir da variância de cada membro do conjunto. Contudo, algumas questões continuam abertas e requerem investigações e novas aplicações. Por exemplo, i) a definição de parâmetros de assimilação, como o número ideal de membros do conjunto, utilizado em alguns casos como valores fixos, em torno de 50 membros (Vrugt et al. 2005) e; ii) a aplicação em modelos operacionais de previsão de vazões com modelos hidrológicos concentrados.

4. METODOLOGIA

4.1. SOPREVA – SISTEMA OPERACIONAL DE PREVISÃO DE VAZÕES

O sistema de previsão de vazões proposto, SOPREVA, é composto por um modelo hidrológico concentrado, para representação do balanço hídrico e propagação dos escoamentos na bacia, e utiliza uma técnica de assimilação de dados para consideração de observações e tentativa de melhoria das estimativas a partir da correção do estado do modelo no instante de partida das previsões.

Para execução do seu modelo hidrológico, este Sistema necessita como dados de entrada: i) séries observadas de vazão e precipitação na bacia; ii) a área da bacia e; iii)

estimativas de evapotranspiração potencial média – que podem ser extraídas de forma automática de Xavier et al. (2015) a partir do fornecimento das coordenadas geográficas do exutório da bacia.

Para a calibração do modelo hidrológico é disponibilizado, além da possibilidade de se efetuar uma calibração manual dos parâmetros, dois métodos de calibração automática – um multiobjetivo (NSGA-II, Seshadri, 2009) e um monobjetivo (SCE, Duan, 2005).

Para geração das vazões previstas, é então necessário o fornecimento da série de precipitações previstas para o período desejado. Estas estimativas podem ser produtos de modelos meteorológicos, para precipitações futuras, e é possível fornecer múltiplas séries, correspondentes a um Ensemble de estimativas de precipitações, ou trabalhar com apenas previsões quantitativas, que podem se referir a uma estimativa média ou para os casos de análises de previsão com chuva real.

O funcionamento geral do sistema SOPREVA é apresentado na Figura 5, e seus módulos são detalhados nas sessões seguintes.

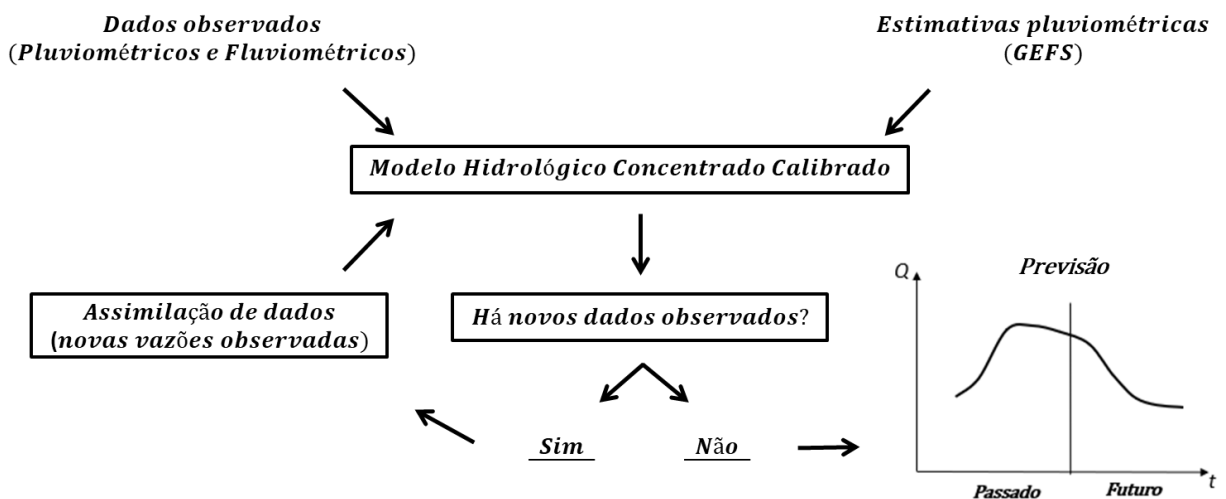


Figura 5 - Fluxograma representativo do sistema de previsão de vazões proposto neste trabalho.

Para facilitar a utilização do sistema, o SOPREVA é disponibilizado com uma interface gráfica constituída das seguintes abas: i) leitura de dados de entrada; ii) calibração do modelo hidrológico e visualização das simulações; iii) determinação de parâmetros de previsão e assimilação de dados; iv) entrada de dados de previsão e; v) apresentação de estimativas.

4.1.1. Modelo Hidrológico

O modelo hidrológico chuva-vazão utilizado consiste em uma versão simplificada, concentrada, do modelo hidrológico MGB-IPH (Collischonn e Tucci, 2001; Collischonn *et al.*, 2007; Paiva *et al.*, 2013b) cujas considerações de balanço hídrico e propagação de escoamentos

são apresentadas a seguir. A Figura 6 ilustra um esquema geral do modelo hidrológico utilizado e este segue explicado a seguir.

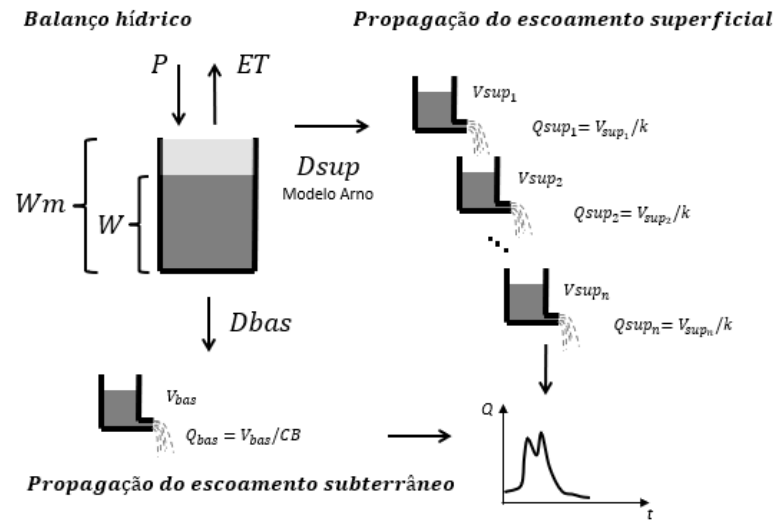


Figura 6 – Esquema geral do modelo hidrológico concentrado utilizado.

A bacia hidrográfica é, portanto, neste modelo representada pelos seguintes componentes: reservatório para representação do armazenamento de água no solo; reservatório linear para propagação de água subterrânea e; cascata de reservatórios lineares, em série, para propagação de águas superficiais.

Primeiramente, baseia-se na consideração de Todini (1996), que descreve o modelo ARNO, no qual o armazenamento da água no solo da bacia pode ser representado por um conjunto de elementos de armazenamento, com diferentes volumes.

Desta forma, a representação do escoamento superficial é dada a partir do momento que a água da chuva precipita na bacia e pelo menos um dos elementos encontra-se cheio, representando uma parcela saturada do solo. Segundo Todini, (1996), com essa abordagem é possível simular o comportamento fortemente não-linear da geração de escoamento.

Assim é então considerado que para diversos pontos da bacia a capacidade máxima de armazenamento de água no solo obedece a uma distribuição estatística que pode ser expressa como uma função simples, conforme apresentada na Equação 1.

$$x = 1 - \left(1 - \frac{w}{w_m}\right)^b \quad (1)$$

onde, x é a fração de elementos de armazenamento cuja capacidade é igual ou inferior a w ; w é o armazenamento de água na camada superficial do solo; w_m é a capacidade de armazenamento do maior dos elementos e; b é um parâmetro do modelo.

No modelo é então realizado o balanço de volume no solo (Equação 2) pela consideração do armazenamento atual de água no solo, precipitação ocorrida, evapotranspiração e frações escoadas, subterrânea e superficialmente.

$$w_{t+1} = w_t + P - ET - D_{Sup} - D_{Bas} \quad (2)$$

onde, w_{t+1} é o volume de água no solo no intervalo de tempo seguinte; w_t é o volume de água no solo no tempo t atual; P é a precipitação ocorrida no passo de tempo; ET é a evapotranspiração; D_{Sup} representa a geração de escoamento superficial e; D_{Bas} representa o volume percolado no intervalo de tempo.

Para aplicação do balanço apresentado na Equação 3, devem ser utilizadas estimativas mensais de evapotranspiração potencial de referência. Considera-se, então, que a evapotranspiração aumenta conforme disponibilidade de água na camada superficial e que há um limite mínimo de umidade do solo a permitir a evapotranspiração (ET). Na Equação 3a, o parâmetro ponderador multiplicativo k_c pondera o uso e ocupação do solo da região, já que os valores disponibilizados por Xavier et al. (2015) representam uma evapotranspiração potencial de referência para solos com grama. O parâmetro w_s representa um limiar em que a evapotranspiração é reduzida a partir da quantidade de água no solo. Contudo, com o objetivo de reduzir o número de parâmetros e, com isso, auxiliar também no processo de calibração, estes dois parâmetros são reduzidos a um parâmetro ponderador k_p e é fixado em 0,5. Assim, o valor da ET a ser utilizado no balanço de água é determinado conforme Equação 3b

$$ET = EP * k_c * \min\left(1, \frac{w}{w_m * w_s}\right) \quad (3a)$$

$$ET = EP * k_p * \min\left(1, \frac{w}{w_m * 0,5}\right) \quad (3b)$$

onde, EP é a evapotranspiração potencial de referência; w é o armazenamento de água na camada superficial do solo e; k_p é um parâmetro ponderador calibrável.

O volume escoado D_{Sup} é determinado então pelas Equações 4a, quando a precipitação P é suficiente para saturar toda a área, e 4b, em caso contrário. Já o volume D_{Bas} é então determinado pela Equação 5, onde k_{Bas} é o parâmetro referente a taxa percolada para o aquífero.

$$D_{Sup} = P - (w_m - w) \quad (4a)$$

$$D_{Sup} = P - (w_m - w) + w_m * \left[\left(1 - \frac{w}{w_m}\right)^{\frac{1}{b+1}} - \frac{P}{w_m * (b+1)} \right]^{b+1} \quad (4b)$$

$$D_{Bas} = k_{Bas} * \frac{w}{w_m} \quad (5)$$

A partir da geração dos volumes de escoamentos, o modelo considera que o comportamento da bacia pode ser representado de forma semelhante à propagação em reservatório linear para o escoamento subterrâneo ou, no caso do escoamento superficial, em uma cascata destes reservatórios lineares, cujo quantificação é um parâmetro do modelo.

A Equação 6 representa a vazão escoada de cada um dos n reservatórios superficiais, onde V_{Sup_n} é o volume presente naquele reservatório e k é um coeficiente de recessão, e a Equação 7 refere-se à vazão subterrânea escoada, onde V_{Bas} é o volume atual do reservatório subterrâneo e CB é o coeficiente de recessão deste. Por sua vez, a vazão na saída da bacia é dada pela Equação 8, como o somatório entra a vazão superficial e a vazão de base.

$$Q_{Sup_n} = V_{Sup_n}/k \quad (6)$$

$$Q_{Bas} = V_{Bas}/CB \quad (7)$$

$$Q = Q_{Sup} + Q_{Bas} \quad (8)$$

Desta forma, a aplicação do modelo hidrológico pode ser representada como uma função das variáveis de estado (X) num tempo anterior (t), das forçantes (u) do modelo e dos parâmetros (θ), conforme Equação 9.

$$\mathbf{x}_{t+1} = M(\mathbf{x}_t, \mathbf{u}, \theta) \quad (9)$$

onde, M é o operador do modelo não linear que relaciona os estados do modelo ao longo do tempo e

$$\mathbf{x} = [w, V_{Bas}, V_{Sup_n}] \quad (10)$$

$$\theta = [w_m, k, CB, k_{Bas}, b, k_p, n] \quad (11)$$

4.1.1.1. Calibração de parâmetros

A calibração do modelo para as doze bacias trabalhadas deu-se de forma manual, posterior a uma etapa preliminar de calibração automática pelo algoritmo NSGA-II, avaliada em termos dos índices de desempenho KGE (GUPTA *et al.*, 2009), coeficiente de Nash-Sutcliffe (Nash e Sutcliffe, 1970) e Nash-Sutcliffe logaritmo. A etapa de calibração manual dos parâmetros foi realizada de forma rápida, sem grandes exigências no desempenho e representação de eventos extremos. Tomou-se como critérios de parada para a calibração: i) a análise visual do hidrograma de forma subjetiva, com avaliação da capacidade do modelo em

representar um comportamento médio da bacia; ii) um limiar de erro de volume inferior a 10% e; iii) um valor da métrica *KGE* próximo ou superior a 0,7.

4.1.2. Assimilação de dados

4.1.2.1. EnKF – *Ensemble Kalman Filter*

O objetivo da assimilação de dados é combinar as estimativas incertas do modelo com as informações de dados observados a fim de fornecer uma otimização dos valores das variáveis de estado do modelo, corrigindo, assim, o estado do modelo para os momentos da previsão. A função que representa a dinâmica do sistema simulado pode ser indicada pela Equação 12 e as observações são dadas pela relação da Equação 13.

$$\mathbf{x}_{t+1} = M(\mathbf{x}_t, \mathbf{u}, \boldsymbol{\theta}) + \mathbf{q}_t \quad (12)$$

$$\mathbf{y}_t = H(\mathbf{x}_t) + \boldsymbol{\varepsilon}_t \quad (13)$$

onde, \mathbf{q}_t representa os erros, podendo ser referentes a estrutura do modelo, estimativas de parâmetros, forçantes ou estados antecedentes; $\boldsymbol{\varepsilon}_t$ é o vetor de erros das observações e H é o operador que relaciona as variáveis de estado às observações \mathbf{y}_t .

Uma grande parte das aplicações hidrológicas dos métodos de assimilação de dados utiliza esquemas baseados no Filtro de Kalman (KF, Kalman, 1960). O KF é um método sequencial de assimilação de dados que utiliza técnicas variacionais e também propaga informação dos erros para os passos de tempo seguintes, computando as covariâncias dos erros em uma matriz adicional (Reichle, 2008).

No caso do Filtro de Kalman original, a AD é resolvida usando um estimador linear assumindo que i) os operadores de modelo e observação são lineares; ii) erros de observação são imparciais e temporal e espacialmente não correlacionados; iii) os erros do modelo são imparciais e temporalmente não correlacionados e; iv) não há correlação entre modelo e erros de observações.

Para contornar algumas limitações do Filtro de Kalman, como a aplicação a sistemas não-lineares, caso da maioria das relações hidrológicas (Liu e Gupta, 2007), e as desvantagens que, tanto o KF original quanto sua versão não-linear, o KF Estendido (EKF), têm quando aplicados em sistemas grandes e complexos com muitas variáveis de estado (Vrugt et al., 2005), foram desenvolvidas variações do método para adaptar seu uso, sendo um dos mais utilizados o Filtro de Kalman por Ensemble (EnKF), apresentado por Evensen (2003 e 2004).

O método se popularizou por ter uma formulação conceitual simples e por ser relativamente fácil de implementar (Evensen, 2003). O EnKF faz uso do método de Monte

Carlo para criar uma função densidade de probabilidade como alternativa à matriz de covariância dos erros (Evensen, 2003).

As etapas para aplicação do método de assimilação de dados são listadas a seguir e ilustradas na Figura 7, Em seguida, o método de assimilação de dados Filtro de Kalman por Conjuntos (*Ensemble Kalman Filter*), a ser aplicado no sistema de previsão proposto, é apresentado de forma simplificada a seguir, baseado em Evensen (2003), Evensen (2004) e Katzfuss et al. (2016).

- I. Inicialização das variáveis de estado (primeiro ΔT);
- II. Perturbação das estimativas de forçantes;
- III. Perturbação das variáveis de estado;
- IV. Correção de possíveis erros físicos (volumes);
- V. Simulação com modelo hidrológico;
- VI. Atualização das variáveis de estado;
- VII. Cálculo do conjunto de estimativas de vazão;
- VIII. Perturbação de observações;
- IX. Aplicação do EnKF;
- X. Correção de possíveis erros físicos;
- XI. Determinação do estado médio do modelo;
- XII. Início das previsões.

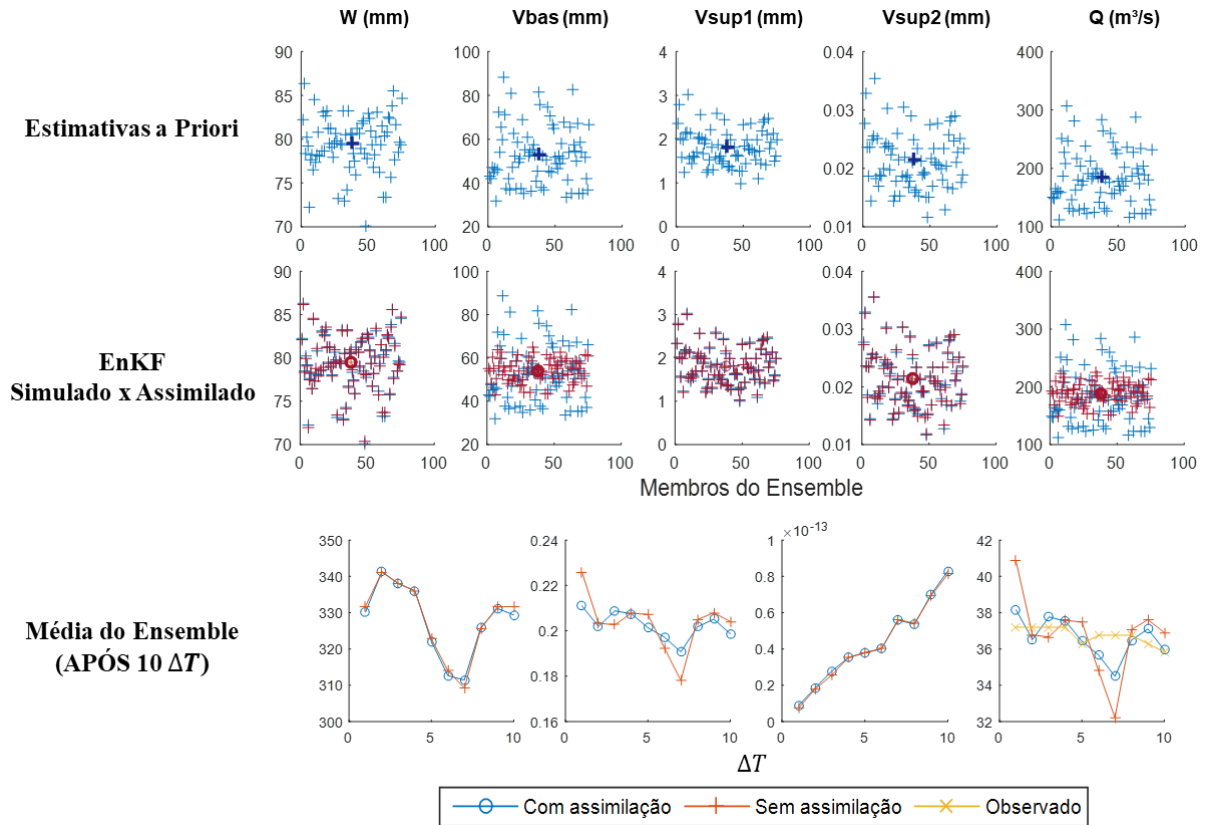


Figura 7 - Ilustração de etapas da aplicação do EnKF ao modelo hidrológico concentrado.

Seja \mathbf{X}^b a matriz das variáveis de estado do modelo (Equação 13), cuja dimensão é $nestado \times nens$, onde $nestado$ é o número de variáveis de estado e $nens$ é o número de membros do conjunto.

$$\mathbf{X}^b = (x_1^b, \dots, x_{nens}^b) \quad (13)$$

A média do conjunto é então definida conforme Equação 14.

$$\bar{x}^b = \frac{1}{nens} \sum (x_i^b) \quad (14)$$

A anomalia de cada membro do conjunto, isto é, a diferença de cada membro do conjunto à média é expressa em nova matriz \mathbf{X}'^b . Então, uma estimativa da covariância do erro do modelo é calculada a partir da Equação 15.

$$\mathbf{P}^b = \frac{1}{nens - 1} \mathbf{X}'^b \mathbf{X}'^{bT} \quad (15)$$

Assim, as variáveis de estado no modelo são atualizadas, com base nas Equações 16a e 16b.

$$\mathbf{x}_i^a = \mathbf{x}_1^b + \mathbf{K}(y_i - H\mathbf{x}_1^b) \quad (16a)$$

$$\mathbf{K} = \mathbf{P}^b \mathbf{H}^T (\mathbf{H} \mathbf{P}^b \mathbf{H}^T + \mathbf{R})^{-1} \quad (16b)$$

$$y = Q_{obs} \quad (17)$$

onde, \mathbf{x}_i^a representa a variável atualizada, y_i é o vetor de observações de vazões, H é um operador que leva as variáveis de estado à mesma dimensão das observações, K representa o ganho de Kalman e R é a matriz de covariância das observações.

Na prática, a implementação do EnKF nesse sistema inicia com a perturbação das séries das variáveis de estado \mathbf{X} – precipitação, armazenamento de água no solo, volume de água nos reservatórios superficiais e subterrâneos e evapotranspiração – para a geração dos membros do conjunto a serem propagados pelo EnKF em cada passo de tempo. A geração deste conjunto de membros é realizada com o intuito de representarem as incertezas das estimativas antecedentes.

A geração e implementação de tais perturbações nas variáveis de estado do modelo foram baseadas na Equação 18, considerando que os erros seguem uma distribuição log-normal, assim como aplicado nos trabalhos de Paiva et al. (2013), Nijssen et al. (2004) e Andreadis & Lettenmaier (2006).

$$V_c = \left[\frac{1 + \beta}{\sqrt{E^2 + 1}} \exp\left(\sqrt{\ln(E^2 + 1)} \epsilon\right) \right] V \quad (18)$$

onde, V_c é a variável perturbada; V é o valor presente para tal variável; E é a estimativa do erro relativo (%) da variável e β o viés relativo, considerado 0; ϵ é a variável aleatória extraída da distribuição normal

4.2. AVALIAÇÃO DO SISTEMA SOPREVA – ÁREAS DE ESTUDO E DESCRIÇÃO DOS EXPERIMENTOS

Esta seção do trabalho destina-se a apresentar as áreas de estudos, com descrição de suas características e apresentação dos dados observados utilizados para cada uma delas; e os experimentos utilizados para validação e análise do desempenho do sistema de previsão proposto.

A proposição dos experimentos é embasada pelos objetivos de i) avaliar a estrutura do SOPREVA – modelo hidrológico concentrado e assimilação de dados; ii) avaliar a aplicabilidade do Sistema em bacias com diferentes características hidrológicas; iii) analisar parâmetros de assimilação de dados, decorrentes da aplicação do EnKF; iv) verificar a

performance do Sistema com uso de estimativas de precipitação oriundas de modelo meteorológico e, por fim; v) verificar a aplicabilidade do SOPREVA na previsão por Ensemble.

Um fluxograma da metodologia deste trabalho, ilustrando a sequência de experimentos aplicados para avaliação e validação do sistema de previsão é apresentado a seguir na Figura 8. Os tópicos posteriores descrevem os métodos aplicados em cada experimento.

Preparação do sistema de previsão:

Experimentos de Avaliação do Sistema:

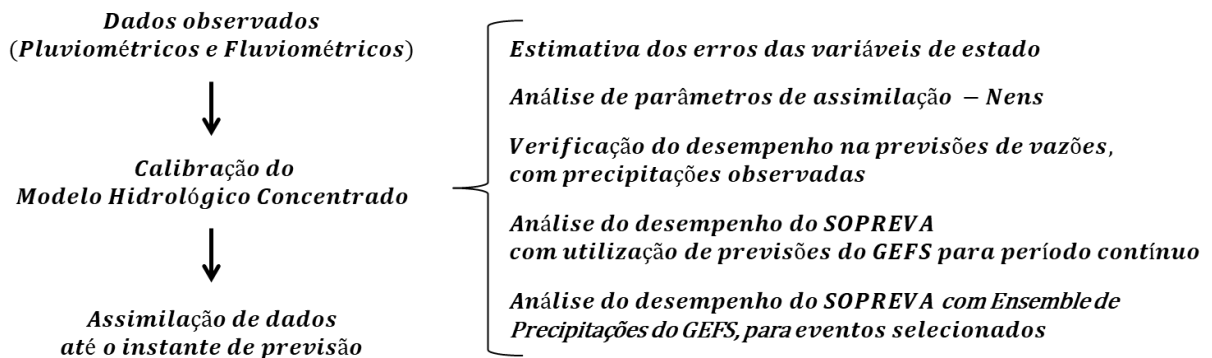


Figura 8 - Fluxograma de metodologia do trabalho para aplicação dos experimentos.

4.2.1. Áreas de estudo e dados de entrada do Sistema

Foram escolhidas doze bacias hidrográficas a fim de verificar a aplicabilidade do SOPREVA, mediante experimentos posteriormente apresentados, para diferentes regiões e características físicas distintas.

Desta forma, a escolha das bacias deu-se mediante os seguintes critérios i) disponibilidade de dados horários de precipitação e vazão, fornecidos pela Agência Nacional de Águas – ANA, em plataforma online; ii) localidades diversas, a fim de submeter o Sistema em avaliação a bacias de diferentes regiões (ilustrado na Figura 9) e; iii) tamanhos de bacias variados, com representação de bacia com menos de 1000 km² a bacia de até 220000 km². Um maior detalhamento das características das bacias é fornecido no item seguinte.

Os dados observados de precipitação e vazão foram obtidos a partir de plataforma online da ANA e o intervalo a ser trabalhado foi determinado mediante verificação de falhas na série histórica.

Diante do grande número de falhas nas séries de dados de vazão e precipitação, alguns casos específicos foram tratados com o preenchimento de falhas, a fim de aumentar a continuidade das séries históricas.

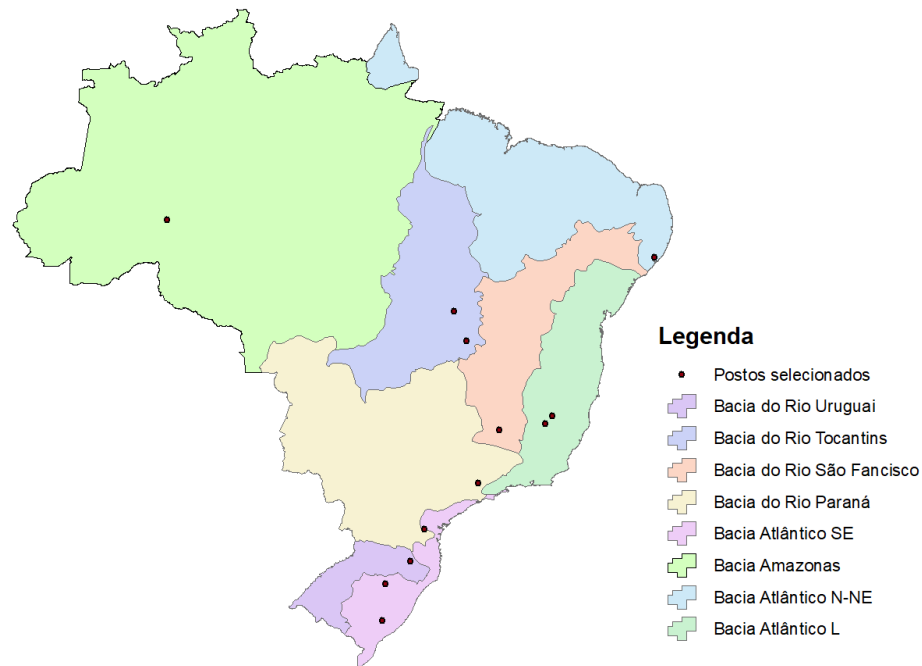


Figura 9 - Localização no território brasileiro dos postos fluviométricos utilizados como exutórios das bacias.

No caso de ausência de dados na série de vazão, em uma certa hora em que há medição nos horários imediatamente anterior e posterior, a falha foi preenchida pela média das duas medições.

Na série de precipitação, para ausência de dado em uma certa hora em que há medição em até duas horas de diferença (anterior e futura) e tal medição for de precipitação nula, o dado foi preenchido como se não houvesse precipitação. Casos de falhas além dos supracitados foram mantidas as ausências dos dados e, portanto, não utilizados nas assimilações de dados executadas.

Para as estações que apresentavam dados com discretização de 15 minutos, os dados foram transformados para discretização horária a partir de acumulação, para os dados de precipitação, e média, para os dados de vazão.

Assim, foi possível obter continuidade nas séries históricas de forma a captar ao menos dois eventos chuvosos da bacia. A Tabela 1 contém o período selecionado da série histórica e a extensão da série resultante em dados horários para cada bacia, apresentadas a partir de agora pelo nome do posto fluviométrico.

Salienta-se que, devido a esta limitação na extensão da série de dados mencionada, as análises de desempenho de previsão feitas neste trabalho são com aplicação para o mesmo período em que o modelo foi calibrado.

Para as análises com dados diários, aplicadas à Pires, Labrea, UHE Campos Novos, PCH João de Deus e Governador Valadares, o período de análise foi semelhante ao utilizado nas análises com dados horários, para viabilizar a possibilidade de comparação dos resultados.

Tabela 1 - Informações sobre as séries de dados observados de precipitação e vazão.

Bacia	Período	
UHE Campos Novos	18/09/2015 18:00	11/03/2018 00:00
Flores de Goiás	27/03/2015 05:00	25/04/2017 10:00
Guajuvira	04/04/2014 16:00	06/11/2016 11:00
Guaporé	10/06/2009 09:00	11/11/2012 08:00
PCH João de Deus	11/03/2016 11:00	12/03/2018 00:00
Pires	30/11/2014 01:00	08/11/2017 23:00
UHE Peixe Angical	18/09/2015 18:00	29/10/2018 00:00
Governador Valadares	01/04/2014 01:00	29/10/2018 23:00
Labrea	13/11/2016 13:00	01/08/2018 20:00
Passo do Mendonça	22/06/2015 16:00	29/10/2018 00:00
Fazenda Boa Fortuna	09/05/2014 06:00	23/10/2018 23:00
Belo Oriente	19/12/2013 16:00	29/10/2018 00:00

Os dados de evapotranspiração potencial, a serem utilizados como entrada do modelo hidrológico concentrado, foram obtidos através de Xavier et al. (2015). Tal processo deu-se a partir do fornecimento das coordenadas dos exutórios de cada bacia no SOPREVA. Assim, os valores de *EP* mensais utilizados são baseados nas estimativas médias do trabalho supracitado para o período de 1980 a 2013.

4.2.1.1. Caracterização das áreas de estudo

Como mencionado anteriormente, a seleção das bacias a serem analisadas deu-se mediante interesse de se trabalhar com uma grande variação das características físicas e hidrológicas. Assim, o Sistema proposto neste trabalho poderia ser efetivamente avaliado e sua aplicabilidade melhor discutida.

A Tabela 2 contém um resumo das características de cada uma das doze bacias hidrográficas. Ressalta-se que nesta tabela é apresentado o nome do posto fluviométrico e a bacia principal da qual faz parte. Entretanto, para as demais seções do trabalho, as bacias trabalhadas serão referenciadas através do nome do posto fluviométrico.

Analisando as informações apresentadas na tabela, observa-se que há uma grande variabilidade nas características das bacias. Dentre estas bacias, há uma com área de drenagem inferior a 1000 km² e uma bacia com área de drenagem superior a 200000 km². As demais bacias apresentam porte intermediário a estas, mas ainda havendo bacias com área superior a 40000 km². Estas escolhas são resultantes da proposta de avaliar o desempenho de um modelo hidrológico concentrado aplicado a grandes bacias e a eficiência da técnica de assimilação de dados na melhoria do desempenho desse modelo para previsões de vazões.

O comportamento hidrológico e porte das bacias também segue representado com situações distintas através da variabilidade nos coeficientes de escoamento, através da quantificação da Q50, bem como pela sazonalidade dos eventos – evidenciado nas séries de precipitações, apresentadas na Figura 10.

Tabela 2 – Características das bacias selecionadas para estudo

Postos	Bacia	Rio	Área de drenagem (km ²)	Tempo de pico (dias)	Q50* (m ³ /s)	Coefficiente de Escoamento	Precipitação média* (mm/ano)	Coefficiente de Assimetria	CV	Q90/Q50
UHE Campos Novos	Rio Uruguai	Rio Canoas	4720	5.5	106.	0.43	1979	2.1	1.66	3.13
Flores de Goiás	Rio Tocantins	Rio Paranã	7210	1.2	11.5	0.08	907	2.2	2.33	4.30
Guajuvira	Rio Paraná	Rio Iguaçu	2330	4.1	45.8	0.38	1861	1.6	3.04	2.91
Guaporé	Rio Taquari	Rio Guaporé	2470	2.0	27.9	0.36	1941	7.6	2.81	5.01
PCH João de Deus	Rio São Francisco	Rio Lambari	11850	4.2	9.2	0.04	848	1.8	2.90	3.92
Pires	Rio Paraná	Rio Jaguarí	955	3.3	11.5	0.24	1686	4.3	3.09	2.35
UHE Peixe Angical	Rio Tocantins	Rio Tocantins	40100	3.6	100.0	0.11	1242	6.4	3.02	3.84
Governador Valadares	Rio Doce	Rio Doce	40500	4.8	174.1	0.16	795	6.7	2.75	2.05
Labrea	Rio Purus	Rio Purus	226000	109.9	2954.0	0.22	2641	0.4	2.12	3.72
Passo do Mendonça	Lagoa dos Patos	Camaquã	15600	1.8	150.7	0.32	1650	3.0	1.85	4.36
Fazenda Boa Fortuna	Rio Mundaú	Rio Mundaú	3560	1.4	15.5	0.14	1425	7.6	1.64	3.70
Belo Oriente	Rio Doce	Rio Doce	24200	1.9	116.1	0.18	912	3.5	1.65	2.55

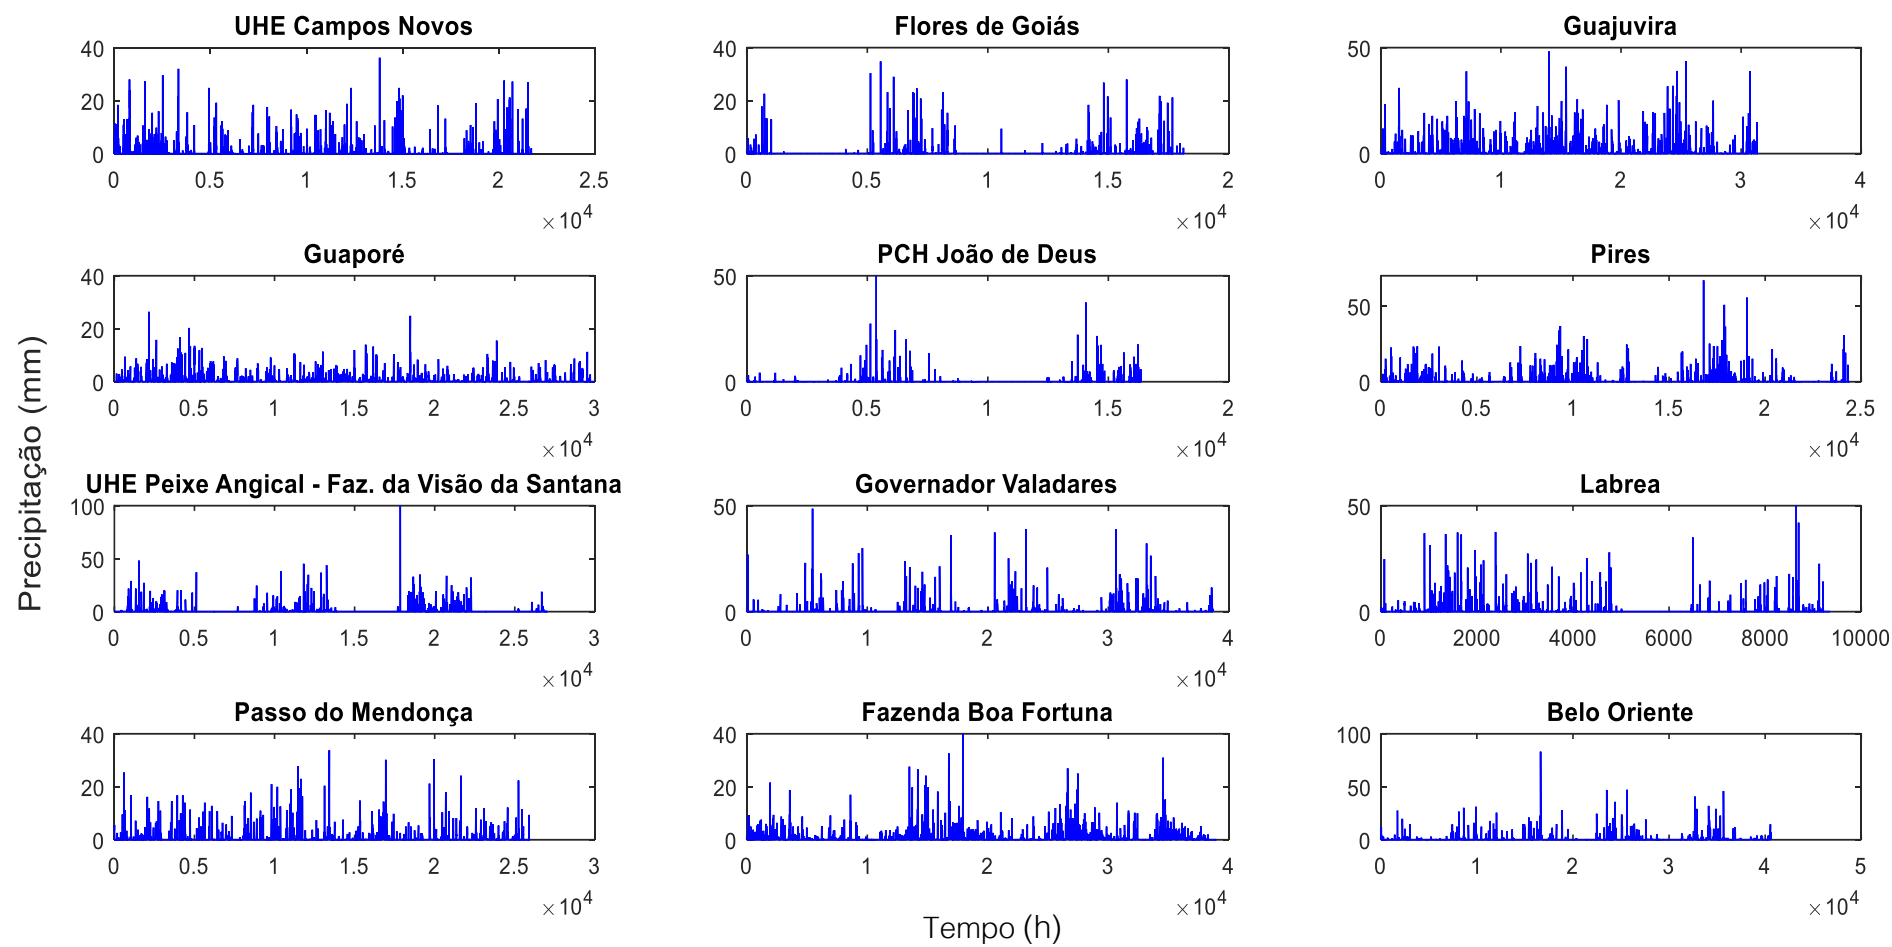


Figura 10 – Séries pluviométricas horárias (mm/h) das áreas de estudo, disponibilizadas pela Agência Nacional de Águas.

4.2.2. Estimativas dos erros das variáveis de estado

Para a avaliação e estimativa dos erros do modelo para cada variável de estado em cada bacia foi realizada uma análise de sensibilidade, de forma a determinar o valor de erro a ser utilizado a no processo de assimilação de dados. Tal análise de sensibilidade foi realizada a partir das seguintes etapas:

- i) uma rodada do sistema admitindo-se que não existem erros nas variáveis de estado;
- ii) uma sequência de rodadas do modelo com perturbação em apenas uma variável, a partir dos valores de erros pré-estabelecidos de 5% a 30%;
- iii) rodadas do sistema com perturbação em todas as variáveis de forma conjunta, com os valores ótimos encontrados para cada variável;
- iv) rodadas do sistema com perturbação em todas as variáveis de forma conjunta, com os valores vizinhos aos ótimos encontrados na etapa (ii), de forma a confirmar se a ponderação conjunta dos erros das variáveis alteraria o valor ótimo do erro de cada variável.

Foi considerado o valor ótimo para a estimativa do erro de cada variável aquele que quando utilizado resultava em melhores desempenhos nas previsões (com horizontes de até 168h - 7 dias), medidos através do coeficiente de Nash-Sutcliffe. Para os casos em que não foi possível determinar uma estimativa de erro que gerasse melhor desempenho para todos os horizontes de previsão, foi analisada graficamente a estimativa que mais predominava como valor ótimo.

4.2.3. Definição do número de membros do Ensemble

Para a determinação das estimativas dos erros de cada variável de estado do modelo (descrita no item anterior) o Sistema foi utilizado com um valor fixo de 50 membros no Ensemble do EnKF, valor utilizado em outros trabalhos a exemplo de Vrugt et al. (2014). Contudo, após a determinação dos erros, foi realizada uma nova análise de sensibilidade sobre este parâmetro de assimilação de dados que determina o número de membros no Ensemble.

A análise consistiu em rodadas do sistema para cada bacia com número de membros (N) variando de 4 a 500. A determinação do número de membros a ser utilizado para cada bacia, semelhante à análise das estimativas dos erros, deu-se através da avaliação do desempenho do sistema, medido pelo coeficiente de Nash-Sutcliffe, para as previsões com horizonte de até 168h. Quando não encontrado um valor ótimo predominante para todos os

horizontes de previsão, o valor de N foi decidido sob ponderação subjetiva entre o desempenho e tempo de simulação gasto com os valores de N que resultaram melhor desempenho.

4.2.4. Previsão de vazões com precipitações observadas (chuva real)

Estas aplicações visam analisar a performance e eficiência do sistema de previsão proposto, o SOPREVA. Aqui, ao realizar as simulações utilizando como chuva prevista a chuva real (isto é, a chuva que de fato ocorreu), podemos avaliar o desempenho do Sistema sem a influência de possíveis erros oriundos da previsão meteorológica.

Assim, a partir do modelo hidrológico previamente calibrado para todas as bacias de estudo e com a utilização de dados observados nas estações telemétricas da ANA, foram geradas previsões, ao longo da série de dados, com horizonte de até 168h (7 dias) e com discretização horária.

A eficiência do Sistema em cada bacia é aqui avaliada em função da média do coeficiente de Nash-Sutcliffe para cada horizonte de previsão (1 a 168h) e da comparação com o coeficiente de permanência (*CP*, Kitanidis & Bras, 1980), que permite uma comparação com o desempenho que seria obtido com a consideração de vazão prevista igual a vazão medida no instante de partida da previsão, conforme Equação 19.

$$CP = 1 - \frac{\left[\sum (Q_i^{obs} - Q_i^p)^2 \right]}{\left[\sum (Q_i^{obs} - Q_{t=0}^{obs})^2 \right]} \quad (19)$$

onde Q_i^p é o valor previsto; Q_i^{obs} é o valor observado; $Q_{t=0}^{obs}$ é o valor observado no instante de partida da previsão e; i é o tempo da previsão.

Em sequência, o desempenho das estimativas do Sistema é então também comparado ao desempenho das previsões sem a utilização de assimilação de dados, a fim de se analisar a contribuição da técnica de assimilação no sistema de previsão proposto.

Para cinco bacias, selecionadas entre as que apresentarem desempenhos mais distintos na etapa supracitada, serão verificadas a qualidade das previsões quando utilizado discretização diária. Tal análise tem como objetivo avaliar o SOPREVA em simulações e previsões com dados diários, que representa a realidade de muitas bacias brasileiras que não possuem monitoramento hidrológico com discretização horária ou com um monitoramento deste tipo ainda muito recente.

Por fim, o desempenho do SOPREVA para cada bacia é relacionado com as características físicas e com componentes hidrológicas, com intuito de verificar se há correlações entre eles que permitam avaliar em que situações, para que tipos de bacia, o

Sistema, com o formato proposto de um modelo hidrológico concentrado com uma técnica de assimilação de dados, tem melhores desempenhos nas previsões.

4.2.5. Previsão de vazões com previsão meteorológica

Após as análises para verificação do desempenho da estrutura do SOPREVA, utilizando chuva real como forçante para realização das previsões, nesta parte do trabalho deseja-se avaliar o funcionamento do Sistema com utilização de dados de previsões meteorológicas para as precipitações futuras.

Esta área de previsão climática teve, nos últimos anos, melhorias contínuas e significativas como resultado do aumento das resoluções trabalhadas; avanços em parametrizações físicas; melhor entendimento químico e físico de aerossóis e; melhores estimativas para o estado inicial, devido ao domínio de melhores técnicas de assimilação de dados (Hammil et al., 2013).

Além destes avanços, há a crescente na disponibilização de grandes quantidades de dados, a exemplo dos provenientes do Global Ensemble Forecasting System (GEFS). Este sistema foi escolhido para ser utilizado neste trabalho devido à facilidade de aquisição dos dados e pela consolidada utilização em trabalhos de previsão de vazões ou análise de eventos extremos (e.g. Fan et al., 2014 e Fan et al., 2015, Shah e Mishra, 2016).

Nesta parte do trabalho as avaliações serão divididas em duas partes: i) análise das previsões em eventos selecionados e ii) análise das previsões em período contínuo. A metodologia aplicada nessas duas abordagens e uma breve explanação sobre o GEFS seguem apresentados nos próximos tópicos.

4.2.5.1. GEFS

O conjunto de dados de previsões meteorológicas por conjunto Global Ensemble Forecasting System (GEFS), da segunda geração do NOAA Global Ensemble Reforecast Data Set, mantido pelo National Center for Environmental Prediction (NCEP) do National Oceanic and Atmospheric Administration (NOAA) dos Estados Unidos, torna um grande volume de dados acessível aos usuários. Para este produto há séries de dados de cerca de 34 anos de extensão - parte destes resultantes de um processo de reforecast (Hammil et al., 2013) - com previsões geradas uma vez por dia.

O GEFS é mantido pelo Centro Nacional de Previsão Ambiental do NOAA, e os dados estão disponíveis online em página pública do Earth System Research Laboratory (<https://www.esrl.noaa.gov/psd/forecasts/reforecast2/download>).

Segundo Hammil et al. (2013) existiram várias razões para criar este extenso conjunto de dados de previsão. A primeira é a expectativa de que a ocorrência de um maior número de amostras de previsão por um modelo estatisticamente consistente leve ao diagnóstico de erros de modelo e ao desenvolvimento de novos algoritmos de calibração, aprimorados para eventos raros e para novas aplicações. Uma segunda razão importante seria a quantificação dos benefícios de se ter disponível dados adicionais, diante da dúvida se realmente seria preciso um tamanho de amostra de treinamento excepcionalmente grande ou os produtos podem ser razoavelmente semelhantes se desenvolvidos com um conjunto de dados de previsão menor, talvez com menos membros, menos anos ou com lacunas de dias entre as amostras.

O conjunto de previsões deste produto é composto por 11 membros, estendendo-se até 16 dias de horizonte, com novas previsões geradas todos os dias. Para os 3 primeiros dias, as estimativas são geradas com discretização de 3 horas e adiante, entre o terceiro e décimo sexto dia de previsão, a discretização é de 6 horas (Hamill et al., 2013).

Para a composição dos membros do conjunto de previsão do GEFS, as perturbações são feitas nas condições atmosféricas iniciais para gerar cada membro. Para a previsão operacional em tempo real, 80 membros são usados para gerar condições iniciais, das quais 20 condições principais são usadas para inicializar a previsão operacional de até 16 dias de antecedência (Shah e Mishra, 2016).

Devido à discretização dos dados do GEFS, para as análises apresentadas a seguir foi considerado que a chuva acumulada no período de três horas (ou seis horas, para os horizontes maiores que três dias) é constante durante este período e, assim, discretizada em dados horários – consideração igualmente realizada por Fan et al. (2015) e Fan et al. (2014).

4.2.5.1. Previsão para período contínuo

Estes experimentos consistem no uso de estimativas de precipitação do modelo GEFS como forçante no modelo hidrológico para previsão de vazões nas bacias de estudo. O objetivo desta parte do trabalho é avaliar o desempenho médio do Sistema ao longo de uma série de dados, simulando o funcionamento operacional.

Para isto, em cada dia da série de dados disponíveis, no instante da 00h, são geradas as previsões de vazões horárias para um horizonte máximo de 24h, a partir das estimativas de precipitação fornecidas pela média dos membros do GEFS.

Contudo, as precipitações utilizadas no modelo até o momento de partida da previsão (tempo 0) são oriundas de dados observados e o último dado de vazão assimilado é o dado observado neste tempo 0.

Ao fim, os desempenhos das previsões com utilização dos GEFS para cada bacia são então comparados com os desempenhos das previsões utilizando chuva real e com os desempenhos das previsões sem utilização de assimilação de dados. Desta forma é possível avaliar os benefícios da utilização de um método de assimilação de dados para previsões com um modelo hidrológico concentrado e a diferença das estimativas devido aos erros do modelo de previsão climatológica utilizado.

4.2.5.2. Previsão em eventos selecionados

Este grupo de experimentos consiste na seleção de determinados eventos hidrológicos ao longo das séries históricas de algumas das bacias de estudo para avaliação da eficiência do SOPREVA com utilização das estimativas de precipitação oriundas do modelo GEFS, com consideração dos 11 membros, consistindo, portanto, em previsões por conjunto.

A avaliação simula o funcionamento do sistema de forma operacional perante eventos específicos e busca, além da verificação da aplicabilidade do SOPREVA na previsão por conjunto, analisar o modelo GEFS como fonte de estimativas de precipitação para o Sistema. Para as previsões por conjunto é feita a quantificação do erro pela média dos membros em relação ao observados e uma análise visual de dispersão dos membros.

4.3. AVALIAÇÃO DE DESEMPENHOS

Conforme mencionado nas seções anteriores, os desempenhos do modelo hidrológico serão determinados a partir do parâmetro de eficiência de Nash–Sutcliffe (*NS*, Nash e Sutcliffe, 1970), pelo parâmetro Logaritmo do Nash-Sutcliffe (*NSLog*) a fim de analisar a eficiência de simulação retirando a valoração às vazões máximas observadas, pelo erro de volume (*BIAS*), a fim de quantificar a proporção não representada pelo modelo, e pelo índice de eficiência de Kling-Gupta (*KGE*, GUPTA *et al.*, 2009), cujas equações são apresentadas a seguir.

Para a avaliação das previsões quantitativas é também utilizado como métrica o coeficiente de persistência (*CP*), já apresentado na Equação 19, que fornece um comparativo do desempenho do modelo com a consideração de a vazão manter-se constante durante todo o período de previsão.

$$CP = 1 - \left[\frac{\sum(Q_i^{obs} - Q_i^p)^2}{\sum(Q_i^{obs} - \bar{Q}_{t=0}^{obs})^2} \right] \quad (19)$$

$$NS = 1 - \left[\frac{\sum(Q_i^{obs} - Q_i^{sim})^2}{\sum(Q_i^{obs} - \bar{Q}^{obs})^2} \right] \quad (20)$$

$$NSLog = 1 - \left[\frac{\sum (\log Q_i^{obs} - \log Q_i^{sim})^2}{\sum (\log Q_i^{obs} - \log \bar{Q}^{obs})^2} \right] \quad (21)$$

$$BIAS = 100 * \left[\frac{\sum Q_i^{obs} - Q_i^{sim}}{\sum Q_i^{obs}} \right] \quad (22)$$

$$KGE = 1 - \sqrt{(1 - r)^2 + \left(1 - \frac{\mu_{sim}}{\mu_{obs}}\right)^2 + \left(1 - \frac{CV_{sim}}{CV_{obs}}\right)^2} \quad (23)$$

5. RESULTADOS

5.1. CALIBRAÇÃO DO MODELO HIDROLÓGICO

O modelo hidrológico concentrado proposto foi inicialmente calibrado para as doze bacias previamente selecionadas para o estudo. A Tabela 3 apresenta o resultado das calibrações com os valores dos parâmetros. Os parâmetros calibráveis do modelo representam: Wm – capacidade máxima de armazenamento do solo; b – parâmetro do modelo ARNO; $kbas$ – parâmetro de percolação para o aquífero; n – é o número de reservatórios em cascata, para representação do escoamento superficial; k – coeficiente de recessão dos reservatórios lineares do escoamento superficial; CB – coeficiente de recessão do reservatório linear do escoamento de base; Kp – parâmetro ponderador da evapotranspiração em relação ao uso e ocupação e à umidade do solo a partir da qual diminui a ET .

Tabela 3 - Parâmetros calibráveis do modelo para as seis bacias de estudo.

Bacia	Wm (mm)	b	$Kbas$ (mm/dia)	n	k (h)	CB (dias)	Kp
UHE Campos Novos	150	0.75	2.4	2	85	7.8	0.1
Flores de Goiás	440	0.08	0.2	1	210	55	0.92
Guajuvira	400	0.68	0.95	2	67	7.1	0.96
Guaporé	120	0.09	1.47	2	13.7	23.89	0.9
PCH João de Deus	650	0.03	0.5	1	95	0.8	2.1
Pires	490	0.17	1.6	2	33	25	1.3
UHE Peixe Angical	760	0.13	0.55	1	100	60	1.15
Governador Valadares	780	0.8	1.95	1	160	120	1.6
Labrea	950	0.35	0.36	3	255	70	1.87
Passo do Mendonça	280	0.35	0.7	3	33	2.6	1.05
Fazenda Boa Fortuna	2300	0.9	0.75	1	60	1	2.1
Belo Oriente	1100	0.2	2	4	25	1	1.3

Esta calibração apresentou desempenhos considerados satisfatórios para posterior aplicações do método de assimilação de dados e estudos de previsões. Os desempenhos das calibrações do modelo para as bacias estudadas são apresentados na Tabela 4, por meio das medidas *KGE*, *NS*, *NSLog* e *BIAS*, apresentadas na seção 4.3

Sabe-se que a partir de um processo de calibração mais minucioso poderiam ser obtidos desempenhos possivelmente melhores, contudo para o foco deste trabalho entende-se que a calibração obtida seja satisfatória para posteriores análises.

Tabela 4 – Medidas de desempenho da calibração manual do modelo hidrológico concentrado.

Bacia	<i>KGE</i>	<i>NS</i>	<i>NSLog</i>	<i>BIAS</i> (%)
UHE Campos Novos	0.7699	0.7194	0.5614	-10.95
Flores de Goiás	0.7868	0.6348	0.4674	0.15
Guajuvira	0.8475	0.7243	0.7399	0.18
Guaporé	0.9019	0.8058	0.7448	0.51
PCH João de Deus	0.6599	0.5053	0.7815	-8.92
Pires	0.7883	0.6566	0.7306	-0.76
UHE Peixe Angical	0.6488	0.6678	0.6754	10.57
Governador Valadares	0.6612	0.5857	0.5604	4.72
Labrea	0.9724	0.9484	0.9576	-0.91
Passo do Mendonça	0.8228	0.7336	0.5742	-3.12
Fazenda Boa Fortuna	0.7267	0.6442	0.6121	-3.64
Belo Oriente	0.7585	0.6434	0.4915	-3.62

Além disso, para algumas bacias, quando comparamos o desempenho da etapa de calibração do SOPREVA com o desempenho de calibração obtido para estas mesmas bacias utilizando o modelo MGB-IPH, contudo com dados diários, podemos observar que foi obtido uma performance próxima a obtida nestes casos. A exemplo, a Tabela 5 apresenta algumas dessas comparações para as bacias UHE Peixe Angical, Governador Valadares, Passo do Mendonça e Fazenda Boa Fortuna, conforme os trabalhos Fan (2015), Lopes (2015), Monte *et al.* (2016) e Siqueira (2015). De forma geral, esse patamar de desempenho das calibrações aqui apresentadas também está de acordo com o desempenho apresentado por Siqueira *et al.* (2018) para calibrações das bacias com áreas semelhantes em toda América do Sul.

Tabela 5 - Comparativo entre desempenho na calibração com o SOPREVA e com o MGB/IPH para algumas bacias analisadas.

Bacia	Calibração - SOPREVA				Calibração – MGB/IPH			
	<i>KGE</i>	<i>NS</i>	<i>NSLog</i>	<i>BIAS</i> (%)	<i>KGE</i>	<i>NS</i>	<i>NSLog</i>	<i>BIAS</i> (%)
Guaporé	0.9019	0.8058	0.7448	0.51	-	0.834	0.910	-13.9

UHE Peixe Angical	0.6488	0.6678	0.6754	10.57	-	0.7210	0.792	7.62
Fazenda Boa Fortuna	0.7267	0.6442	0.6121	-3.64	-	0,81	0,45	12
Passo do Mendonça	0.8228	0.7336	0.5742	-3.12	-	0.689	0.759	-1.46
Governador Valadares	0.6612	0.5857	0.5604	4.72	-	0,75	0,61	-30

5.2. ESTIMATIVA DOS ERROS DAS VARIÁVEIS DE ESTADO

A partir do modelo hidrológico calibrado, foram realizadas análises de sensibilidade para determinar estimativas de erros do modelo para cada uma das variáveis de estado. As Figura 12, Figura 13 e Figura 14 apresentam exemplos desta análise de sensibilidade quando perturbadas cada uma das variáveis, uma por vez, para diferentes estimativas de erros. As análises de sensibilidade para as outras bacias podem ser encontradas no Apêndice 8.1.

De forma geral, observa-se que para qualquer variável uma mínima perturbação, isto é, a consideração de valores de erros pequenos, proporciona melhor desempenho para as previsões, principalmente nas horas iniciais de previsões. Fato este que embasa a decisão de perturbar, mesmo que minimamente todas as variáveis de estado listadas.

Por outro lado, é possível observar que o desempenho do Sistema é mais sensível quanto a perturbações em algumas variáveis do que em outras. Por exemplo, as variáveis correspondentes ao volume de água nos reservatórios superficiais e subterrâneo, principalmente, apresentaram pouca influência no desempenho do modelo quando variado as estimativas de erros. Para estas, em muitas bacias, optou-se por utilizar o menor valor de erro.

As estimativas de erros na evapotranspiração e na precipitação apresentam grande influência no desempenho do modelo. Esta importância apoia-se no fato de que a precipitação é a forçante mais importante no modelo chuva-vazão e que as estimativas de evapotranspiração do Sistema consistem em um valor único anual, sem representação da sazonalidade da variável. Desta forma, é esperado que, em regiões onde esta variável seja mais influente nos processos hidrológicos e mais variável ao longo do ano, tenha-se uma maior sensibilidade do desempenho às estimativas dos erros, como observado, por exemplo, em PCH João de Deus, UHE Campos Novos e Flores de Goiás.

A Tabela 6 contém os valores selecionados como estimativa dos erros das variáveis de estado para cada bacia, após análise de sensibilidade. A análise de sensibilidade perturbando os

valores de erros de todas as variáveis conjuntamente gerou os mesmos resultados que os obtidos na análise individual das variáveis, sendo, portanto, mantidos.

A Figura 11 apresenta um exemplo da variação percentual dos valores das variáveis de estado a partir da aplicação a assimilação de dados para a bacia UHE Campos Novos.

Tabela 6 – Estimativa dos erros das variáveis de estado do modelo para as diferentes bacias.

Bacia	Estimativa dos erros (%)			
	W	Vsub	Vsup	P
UHE Campos Novos	5	25	5	25
Flores de Goiás	25	30	10	20
Guajuvira	25	30	15	30
Guaporé	5	5	20	30
PCH João de Deus	15	30	25	30
Pires	25	30	25	20
UHE Peixe Angical	25	5	5	30
Governador Valadares	10	5	20	20
Labrea	5	5	5	20
Passo do Mendonça	10	5	5	10
Fazenda Boa Fortuna	25	20	30	30
Belo Oriente	25	5	15	20




Figura 11 – Alteração percentual das variáveis de estado pela AD para a bacia UHE Campos Novos.

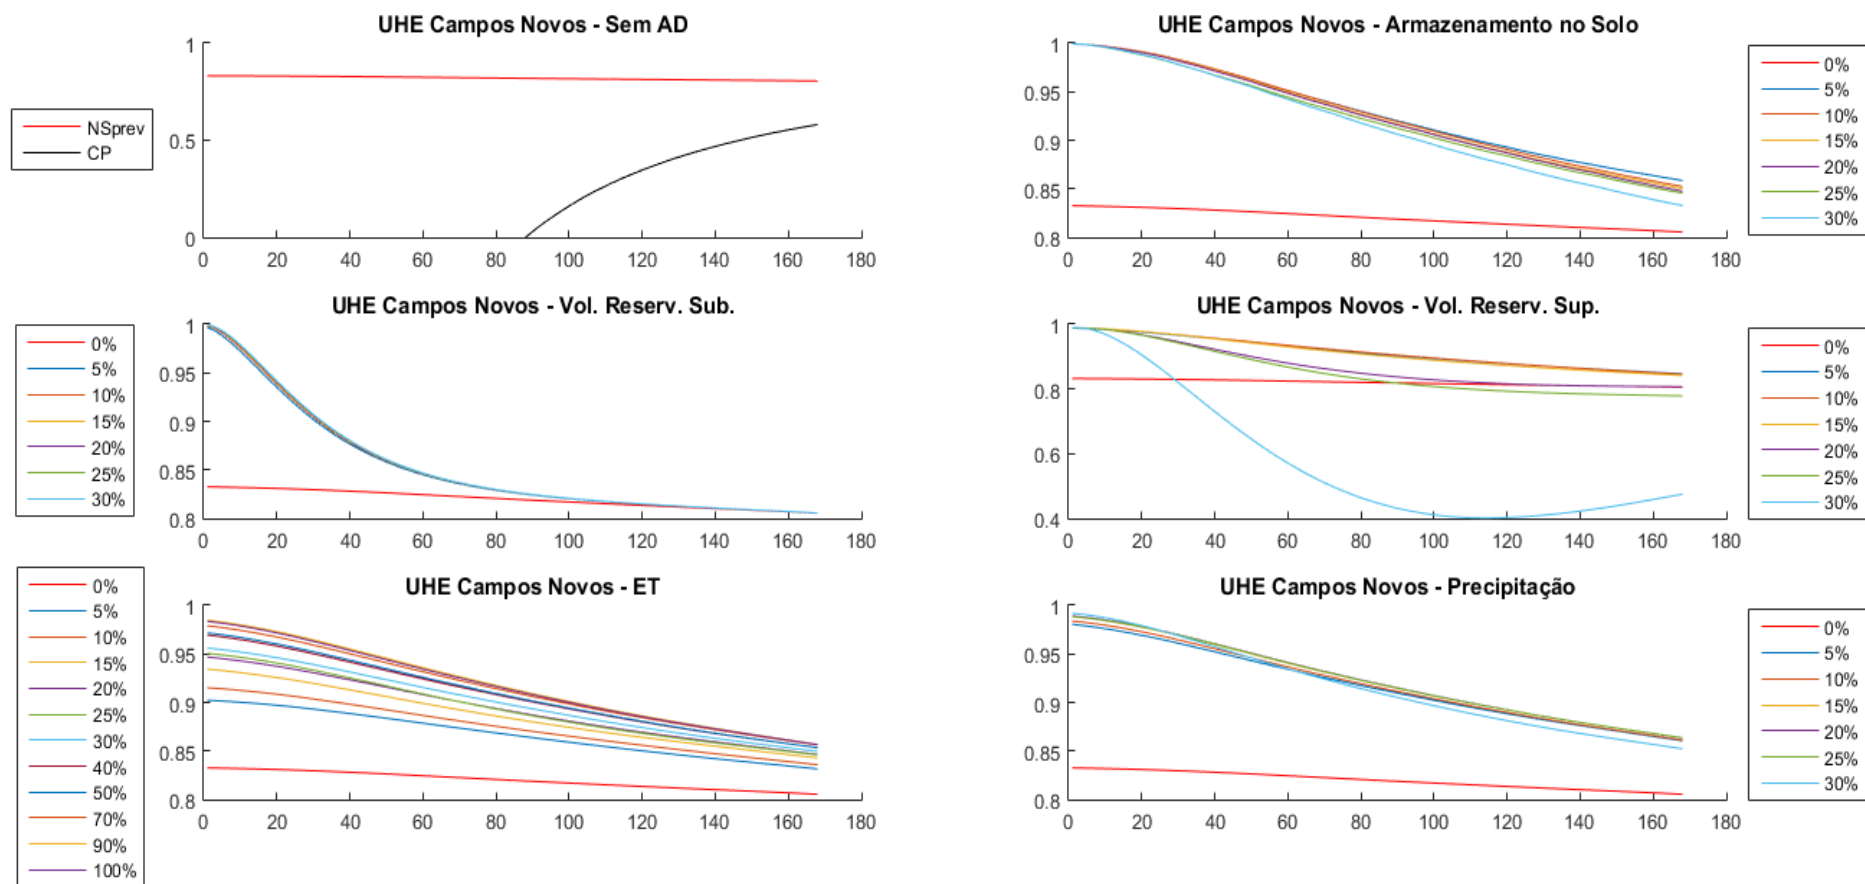


Figura 12 – Análise de sensibilidade das estimativas de erros das variáveis de estado em UHE Campos Novos

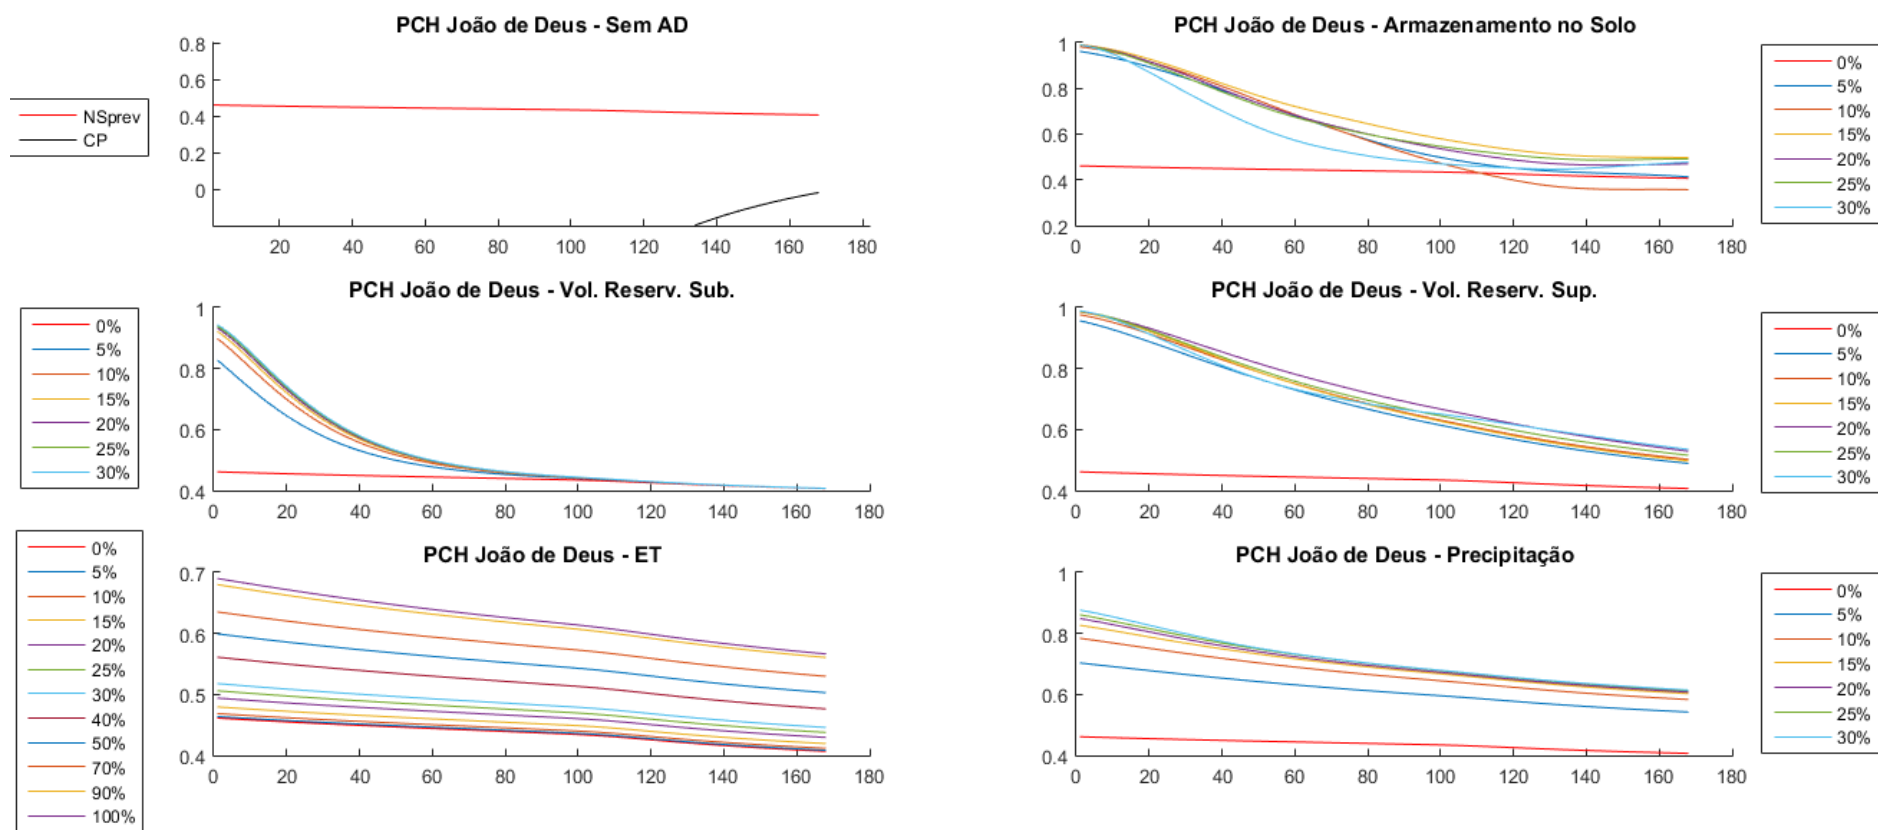


Figura 13 - Análise de sensibilidade das estimativas de erros das variáveis de estado em PCH João de Deus

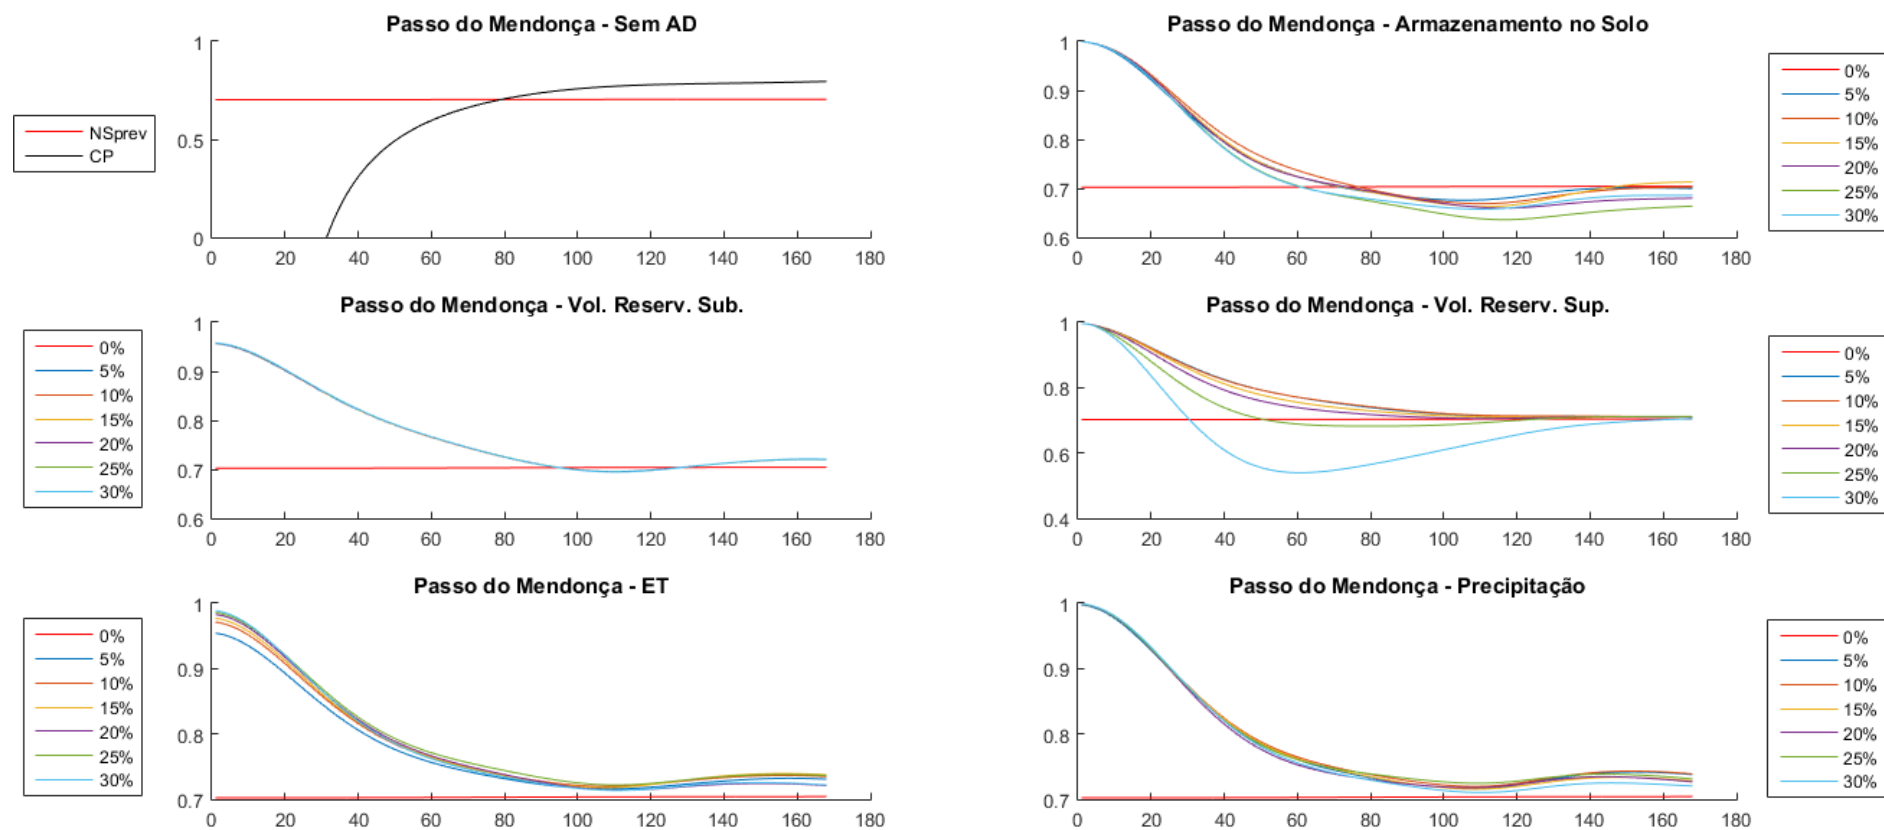


Figura 14 - Análise de sensibilidade das estimativas de erros das variáveis de estado em Passo do Mendonça.

5.3. DEFINIÇÃO DO NÚMERO DE MEMBROS DO ENSEMBLE

Com a definição das estimativas dos erros de cada variável de estado, o Sistema foi aplicado para cada uma das bacias repetidas vezes, com variação no número de membros do Ensemble do EnKF (4 a 500). As Figura 15, Figura 16 e Figura 17 apresentam os gráficos de desempenho nas previsões com horizonte de até 168h (7 dias) para cada variação do número de membros do Ensemble e a relação entre o número de membros com o tempo gasto para simulação, para três das bacias trabalhadas. Os gráficos de análise de sensibilidade deste parâmetro de assimilação para as demais bacias são apresentados no Apêndice 8.2.

De forma geral, observa-se que a escolha por um número muito pequeno de membros no conjunto acarreta em uma queda significativa do desempenho à medida que se aumenta o horizonte de previsão.

Por outro lado, ao aumentar o número de membros no Ensemble há uma melhoria momentânea do desempenho com uma tendência de convergir para uma mesma performance, até um espalhamento em torno do horizonte de 60h. Assim, o aumento demasiado do número de membros não resulta em melhorias significativas, chegando a atrapalhar o desempenho em alguns casos. Além disso, ao considerar um número muito grande de membros, o tempo gasto para as simulações pode aumentar consideravelmente enquanto que a melhoria no desempenho pode não ser significativa.

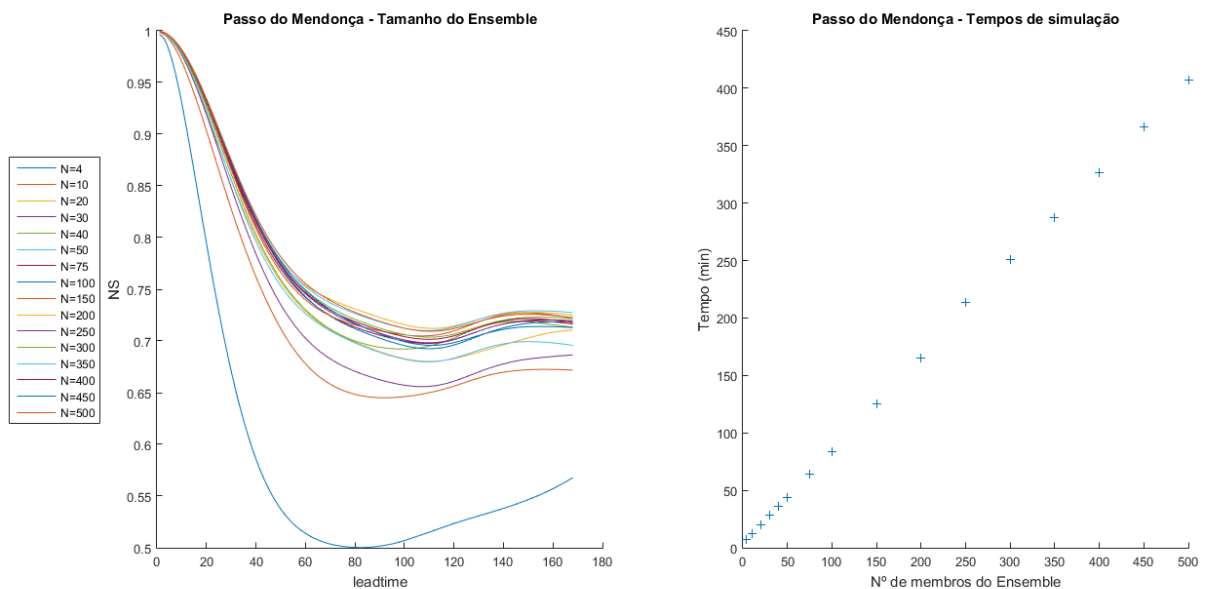


Figura 15 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Passo do Mendonça.

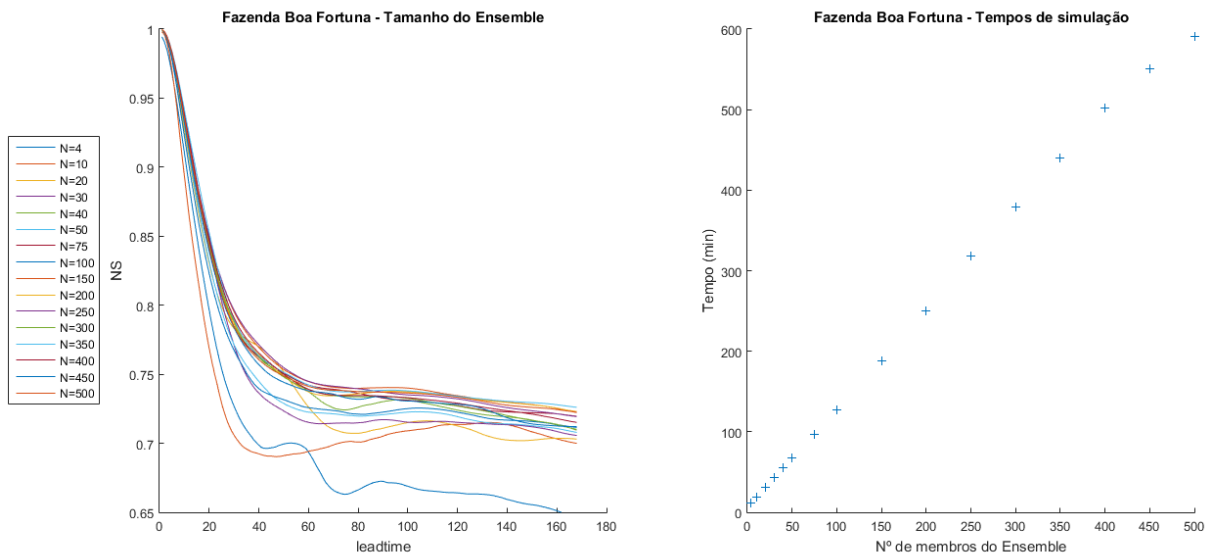


Figura 16 - Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Fazenda Boa Fortuna.

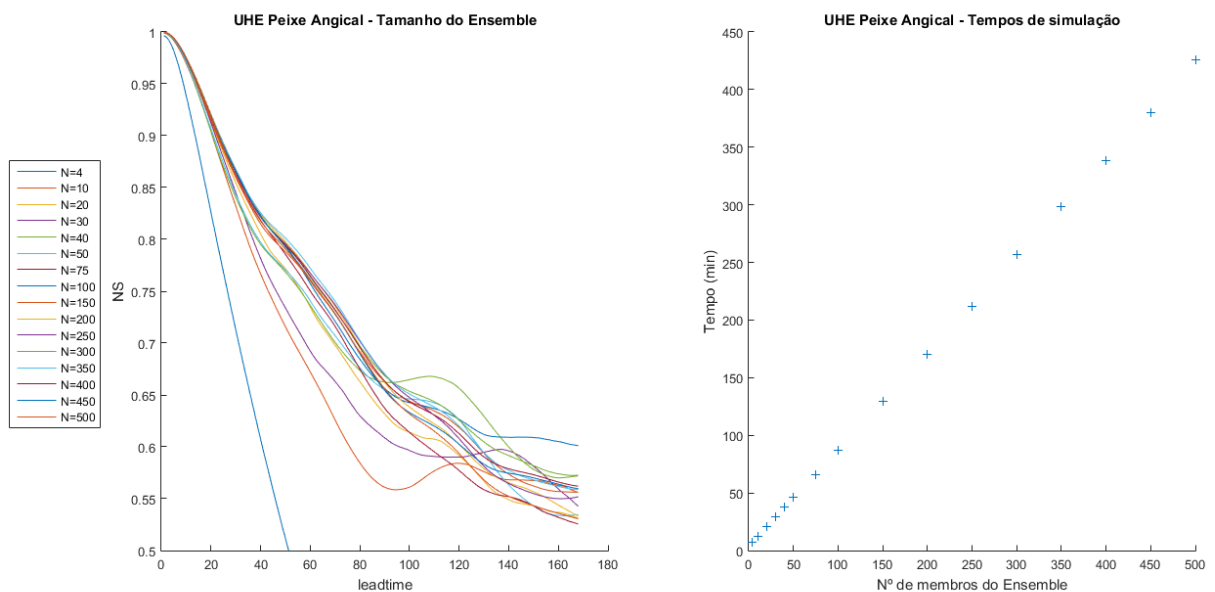


Figura 17 - Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto UHE Peixe Angical.

Ainda no que se refere ao tempo gasto para simulação, é observado que ele apresenta uma relação linear com o número de membros do Ensemble para todas as bacias. Desta forma, quando avaliadas todas as simulações simultaneamente, conforme Figura 18, é possível se obter uma expressão linear bem aproximada para o tempo de simulação em função do número de membros (N_{Ens}) e extensão da série a ser simulada, apresentada a seguir.

$$\text{Tempo de Simulação (min)} = \text{Extensão da Série} * (0.108 * N_{\text{Ens}} + 0.648)$$

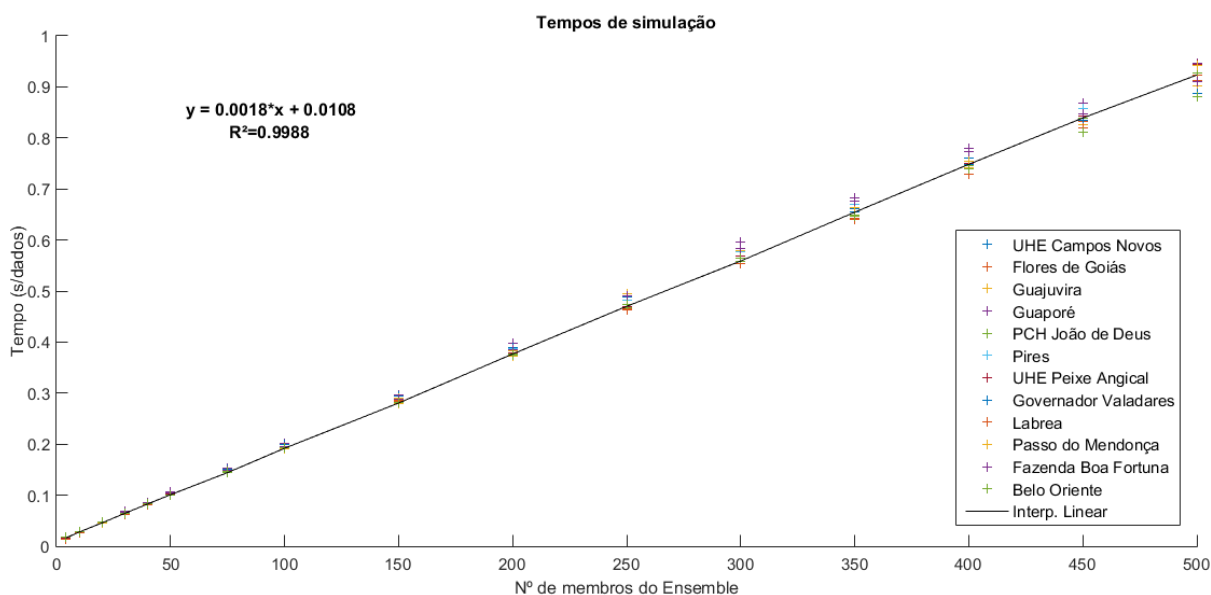


Figura 18 – Ajuste da relação entre o tempo de simulação em função do número de membros do Ensemble e extensão da série simulada.

A tabela apresenta um resumo dos valores definidos para o número de membros do Ensemble para cada bacia após análise acima apresentada.

Tabela 7 – Número de membros do Ensemble definidos para cada bacia.

Bacia	1	2	3	4	5	6	7	8	9	10	11	12
N_{Ens}	75	75	75	40	30	50	100	200	150	200	150	20

5.4. PREVISÕES COM CHUVA REAL

Os resultados apresentados a seguir correspondem às previsões realizadas utilizando os dados observados de precipitação como estimativas futuras, isto é, considerando chuva real. Desta forma é possível discutir o desempenho do sistema de previsão sem a interferência dos erros e incertezas decorrentes da previsão de precipitações.

Para as doze bacias em avaliação foram geradas previsões ao longo de toda a série de dados, com horizonte de até 168 horas. Os gráficos apresentados nas Figura 19 e Figura 21 apresentam um comparativo de desempenho das previsões realizadas com e sem assimilação de dados. Nas cores claras encontram-se os desempenhos das simulações para cada bacia e as linhas sólidas escuras representam as médias das simulações com e sem assimilação de dados, respectivamente, em azul e vermelho.

De maneira geral, o desempenho das previsões utilizando o SOPREVA com assimilação de dados é superior ao desempenho sem a utilização de assimilação de dados, principalmente

nos momentos iniciais de previsão, demonstrando a efetividade do EnKF em melhorar as estimativas do modelo hidrológico concentrado utilizado.

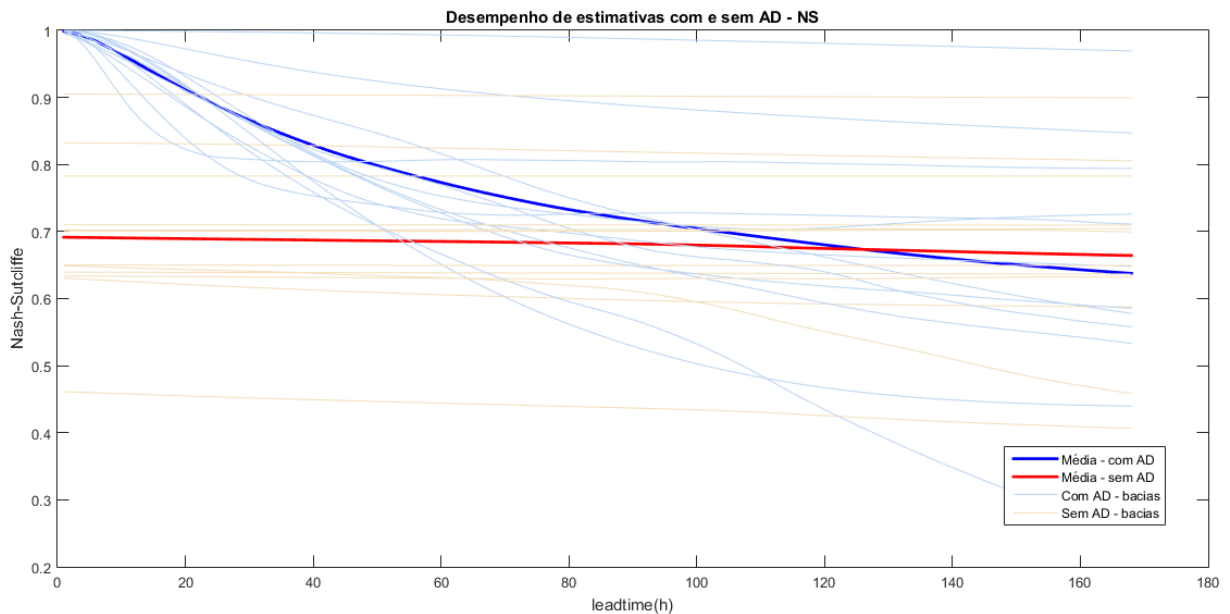


Figura 19 – Comparativo entre desempenho das previsões com e sem assimilação de dados, avaliados através do coeficiente de Nash-Sutcliffe.

Na Figura 20 o desempenho das previsões é então ponderado pelo tempo de pico de cada bacia, na tentativa de avaliar de uma forma mais geral a relação de desempenho para dada uma bacia qualquer. Os pontos críticos representam o momento em que o desempenho das estimativas com assimilação de dados se iguala ao desempenho das estimativas sem assimilação de dados. É verificado que na média a composição do Sistema proposto é vantajosa para um horizonte de pelo menos 1,5 vezes o tempo de pico. Observa-se que para cinco das doze bacias o ponto crítico está além do horizonte de previsão avaliado neste trabalho, o que poderia resultar no aumento deste valor médio de 1,5 vezes o tempo de pico.

Quando avaliado os gráficos do coeficiente de persistência (Figura 21) observa-se que a assimilação de dados torna o Sistema mais efetivo, tornando o seu desempenho melhor do que a consideração de vazão constante, em média, a partir de um horizonte de previsão de cerca de 20h, enquanto que para as previsões sem assimilação de dados o CP atinge o zero em torno de 125h de horizonte de previsão.

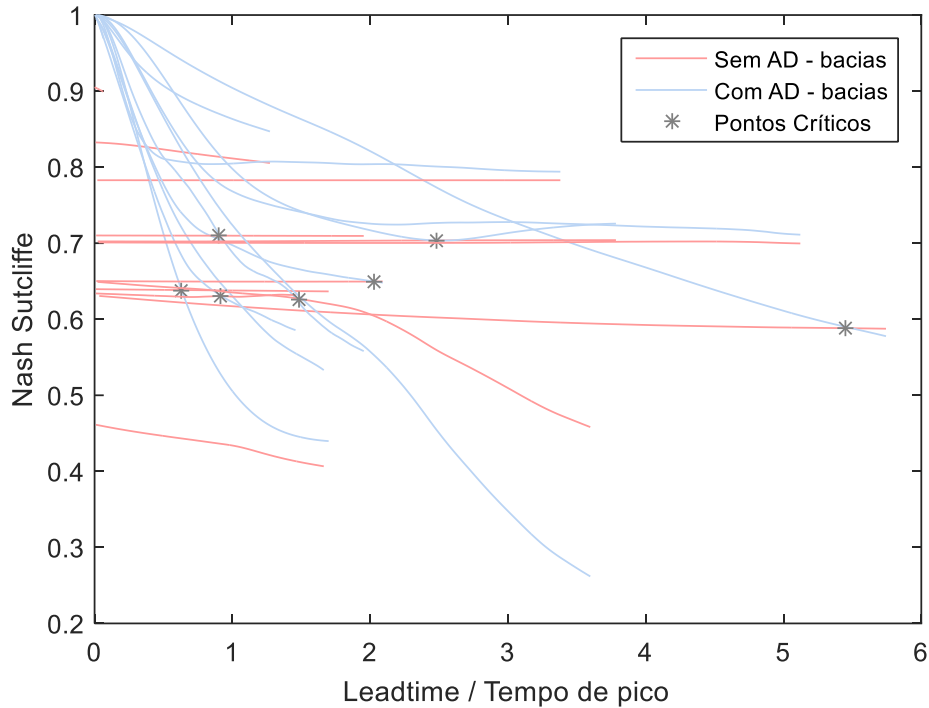


Figura 20 - Comparativo entre desempenho das previsões com e sem assimilação de dados, com ponderação do tempo de pico de cada bacia.

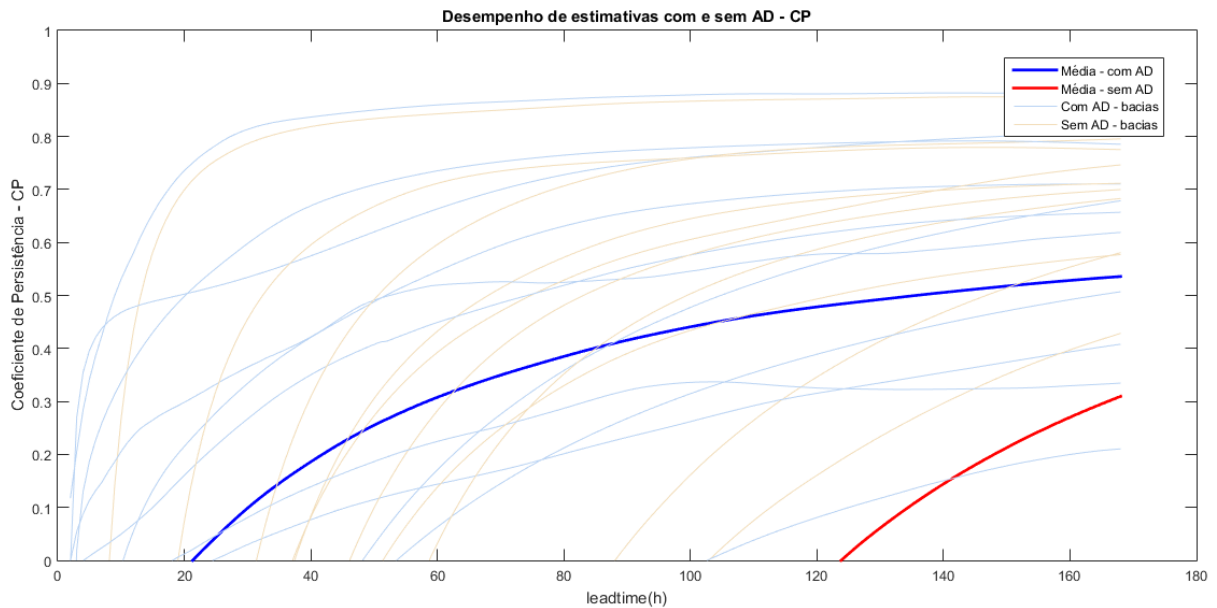


Figura 21 – Comparativo entre desempenho das previsões com e sem assimilação de dados, avaliados através do Coeficiente de Persistência (CP).

A Tabela 8 apresenta um comparativo do desempenho nas previsões com e sem assimilação de dados. Como discutido anteriormente, a técnica de assimilação de dados utilizada, EnKF, foi capaz de melhorar o desempenho na previsão e vazões de todas as bacias para os primeiros dias de previsão. Destaca-se a performance do Sistema para as primeiras horas de previsão, horizonte comumente utilizados em sistemas de alerta, por exemplo.

Tabela 8 – Comparativo entre desempenho de previsões com e sem assimilação de dados.

Bacia	Tipo de Previsão	Desempenho na Previsão		
		NS_5h	NS_24h	NS_168h
UHE Campos Novos	AD	0.9972	0.9650	0.8469
	Sem AD	0.8323	0.8304	0.8054
Flores de Goiás	AD	0.9903	0.9212	0.5777
	Sem AD	0.6286	0.6194	0.5875
Guajuvira	AD	0.9944	0.8907	0.4397
	Sem AD	0.6395	0.6391	0.6366
Guaporé	AD	0.9674	0.8121	0.7940
	Sem AD	0.7828	0.7828	0.7828
PCH João de Deus	AD	0.9858	0.8951	0.5331
	Sem AD	0.4598	0.4537	0.4066
Pires	AD	0.9798	0.8615	0.6480
	Sem AD	0.6501	0.6498	0.6496
UHE Peixe Angical - Faz. da Visão da Santana	AD	0.9941	0.8949	0.5581
	Sem AD	0.7101	0.7101	0.7095
Governador Valadares	AD	0.9813	0.8910	0.5857
	Sem AD	0.6337	0.6325	0.6319
Labrea	AD	0.9996	0.9981	0.9693
	Sem AD	0.9050	0.9043	0.8993
Passo do Mendonça	AD	0.9951	0.9076	0.7257
	Sem AD	0.7023	0.7023	0.7040
Fazenda Boa Fortuna	AD	0.9818	0.8089	0.7112
	Sem AD	0.7009	0.7006	0.6996
Belo Oriente	AD	0.9883	0.8610	0.2618
	Sem AD	0.6478	0.6423	0.4582

Na Tabela 9 é apresentada a performance do Sistema quando utilizado com dados diários para cinco das doze bacias. Os desempenhos sob dados diários são bem próximos aos apresentados anteriormente para dados horários. A assimilação de dados, nestes casos, também favorece no desempenho das previsões para todas as bacias. Este cenário indica a possibilidade de utilização do SOPREVA para simulações e previsões com dados diários, o que o torna mais atrativo diante do fato de que para muitas bacias brasileiras ainda é bem escasso no número de informações hidrológicas com discretização horária.

Tabela 9 – Desempenho do SOPREVA para previsões utilizando dados diários em cinco bacias

Bacia (dados diários)	Tipo de Previsão	Desempenho na Previsão		
		NS_24h	NS_48h	NS_168h
Pires	AD	0.8555	0.7812	0.6676
	Sem AD	0.6190	0.6185	0.6175
Labrea	AD	0.9979	0.9948	0.9694

	Sem AD	0.9556	0.9549	0.9511
UHE Campos Novos	AD	0.9649	0.9277	0.8426
	Sem AD	0.8228	0.8205	0.8200
PCH João de Deus	AD	0.9096	0.7958	0.5452
	Sem AD	0.7100	0.7018	0.7002
Governador Valadares	AD	0.8926	0.7736	0.5669
	Sem AD	0.7467	0.7454	0.7417

Através dos dois gráficos de desempenho, anteriormente apresentados, é possível ver que o desempenho nas previsões ao longo do tempo, sobretudo a forma como ele decai, é bastante diferente entre diferentes bacias. Tal comportamento é esperado pelo fato de se analisar estimativas em 12 bacias com características físicas e comportamentos hidrológicos distintos. Contudo, a escolha dessas bacias, como já mencionado, foi embasada na proposta de avaliar a aplicabilidade do SOPREVA para condições distintas. Desta forma, o desempenho do Sistema para estas aplicações é relacionado com algumas características físicas e hidrológicas, conforme apresentado na Figura 22.

São apresentadas correlações entre o desempenho nas previsões e os seguintes parâmetros: Área da bacia; Tempo de pico; Coeficiente de assimetria das séries de vazões; Q90/Q10; Coeficiente de Variação das séries de vazões; Precipitação média na bacia e; coeficientes de escoamento. O desempenho é correlacionado a partir das métricas: Nash-Sutcliffe para previsões com 24h e 48h de antecedência; diferença relativa entre os valores de NS para estes dois horizontes de previsão supracitados e; raiz do erro médio quadrático entre as previsões para horizonte de 24h e vazões observadas. Altos valores positivos para a correlação entre os NS_24h ou NS_48h e a característica física demonstram uma forte relação entre o aumento da variável característica e a melhoria do desempenho. Já para duas últimas métricas, quanto menor for o coeficiente de relação maior será a correlação entre o aumento da variável característica e a melhoria do desempenho, já que se tratam de erro e decaimento da eficiência.

Para o parâmetro área da bacia é observado a existência de uma relação direta entre aumento da área e melhoria do desempenho. Este fato pode parecer inesperado, já que o SOPREVA utiliza um modelo hidrológico concentrado para suas simulações e este tipo de modelo geralmente está associado com bacias de menor porte. Contudo, bacias de menor porte geralmente são mais difíceis de se acertar na previsão, se comparadas com bacias maiores em um horizonte de previsão relativamente curto e com utilização de uma técnica de assimilação de dados para correção do estado do modelo no instante de partida da previsão. Estas conclusões

são apoiadas quando avaliado a correlação desta característica com o *CP* para o horizonte máximo de previsão, de forma que as maiores bacias são naturalmente mais fáceis de prever para estes horizontes curtos mesmo quando considerado vazões constantes.

Seguindo a mesma ideia, as correlações para a variável característica tempo de pico apoia o fato de que bacias com menor tempo de pico, isto é, apresentam uma resposta mais rápida a determinado evento chuvoso, são mais difíceis de se acertar na previsão.

O coeficiente de assimetria da série de vazões e a relação Q_{90}/Q_{10} são medidas que nos fornecem uma ideia de espalhamento dos dados, ou quão acentuadas são as cheias naquela bacia. Desta forma, a forte correlação negativa entre as primeiras métricas e o coeficiente de assimetria, e também a correlação positiva com a Q_{90}/Q_{10} , sugerem que piores performances foram encontradas para aquelas bacias que apresentam eventos com picos de vazão muito superiores à vazão de base, por exemplo.

A análise de correlação entre o desempenho do sistema com coeficiente de variação (CV) da série de vazões permite avaliar o quanto a qualidade das estimativas depende da sazonalidade encontrada na bacia. Contudo, não foram encontradas altas correlações entre as métricas de desempenho e esta variável. Tal fator parece coerente quando ponderado que as análises realizadas neste trabalho tratam de horizontes de previsão de poucos dias, ou seja, com pouca influência de uma possível variação sazonal, desde que o modelo hidrológico de base física esteja coerente e, portanto, seja capaz de representar o comportamento de uma mesma bacia para situações forçantes distintas.

Ao avaliar as correlações para o Coeficiente de Escoamento, observa-se que maiores coeficientes resultam em maiores erros (RMSE_24h) e piores desempenhos, medidos pelo NS para os horizontes de 24 e 48h. Tal correlação pode ser interpretada como uma dificuldade em prever grandes variações na vazão para eventos chuvosos. Em apoio, quando analisada as correlações de desempenho com a precipitação média, nota-se que maiores índices pluviométricos resultam em menores decaimentos do desempenho das previsões à medida que se aumenta o horizonte das previsões.

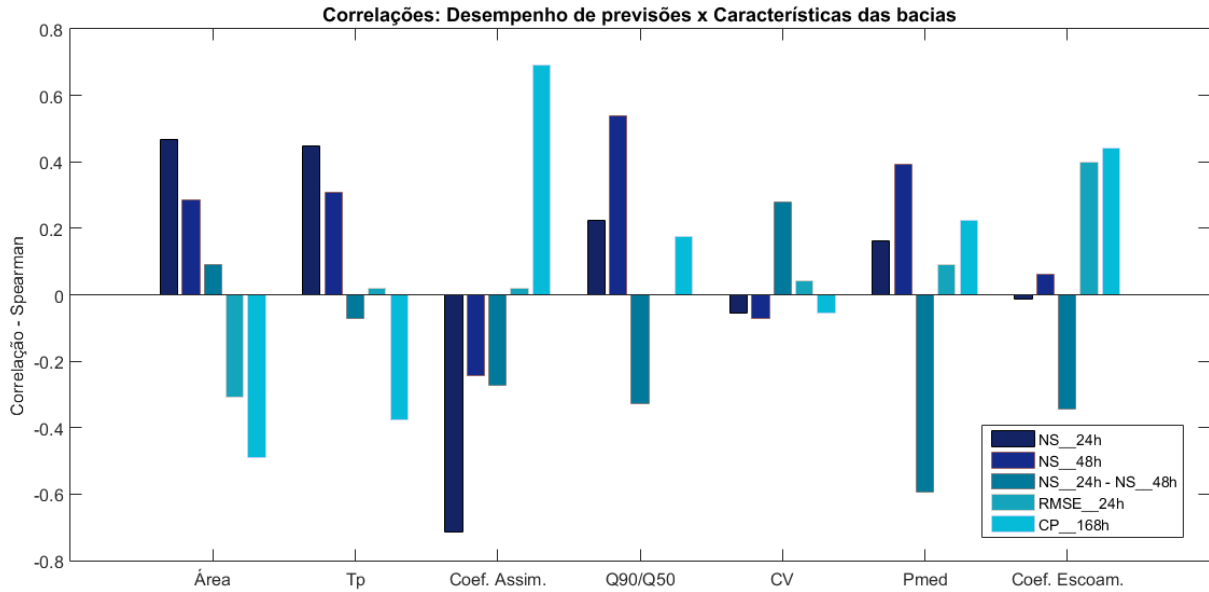


Figura 22 - Correlações de Spearman entre desempenho nas previsões e características das bacias.

A avaliação do desempenho do SOPREVA a partir de análises que consideram o valor do coeficiente de persistência – como mostrado no tópico anterior, Figura 21 – permite uma avaliação do Sistema com o que pode ser considerado o mais simples dos modelos de previsão (quando se considera a vazão no momento de previsão constante para o período previsto). Contudo, esta comparação não supre a necessidade de enquadrar o desempenho do SOPREVA frente a outros métodos de previsão já consolidados. Assim, a seguir são apresentadas algumas ponderações sobre os resultados de previsões para algumas das bacias analisadas a partir de Redes Neurais Artificiais (RNA) ou do MGB/IPH.

Apesar da ponderação do desempenho durante a etapa de calibração com trabalhos que utilizam um modelo de base física, como o MGB/IPH, estes trabalhos não utilizaram os mesmos postos para validação das previsões ou não avaliaram previsões em períodos contínuos e, portanto, são mencionados a seguir pelo desempenho nos postos mais próximos ou apenas pela performance média nos eventos avaliados.

Siqueira (2016) apresenta, para dois eventos em Guaporé, desempenhos medidos pelo coeficiente de NS variando entre 0,85 e 0,93 – primeiro evento – e entre 0,95 e 0,97 – segundo evento, para limites de horizonte de previsão semelhantes aos utilizados neste trabalho.

Gama e Pedrollo (2017) avaliaram o desempenho de uma RNA na previsão de níveis na bacia do rio Mundaú, com avaliação também no posto Fazenda Boa Fortuna. Os autores apontam que os resultados obtidos superam o desempenho dos sistemas de regressão implantados pela CPRM na região para suporte ao sistema de alerta. Para a situação que

apresentou melhor desempenho, os valores de NS neste estudo variaram de 0,98 a 0,92 entre as primeiras 5 e 12h de previsão.

Apesar de não ter avaliado o desempenho das previsões nos mesmos pontos analisados neste trabalho, Fan (2015), com utilização do MGB/IPH, encontrou para o posto Iguatama, na bacia do rio São Francisco, um NS no período de verificação do modelo de 0,71. Este posto, assim como o PCH João de Deus (avaliado neste trabalho) encontra-se na região de cabeceira do rio São Francisco. Não podemos tomar este valor de NS como referência do desempenho médio das previsões, contudo, este valor é semelhante ao obtido pelo SOPREVA nas previsões sem assimilação de dados.

Para a bacia do rio Tocantins, apesar de não ter avaliado o desempenho do modelo na etapa de verificação ou previsão no posto Peixe Angical, o referido autor apresenta que o melhor desempenho na etapa de verificação na bacia foi com valores de NS de 0,78, para o posto UHE Estreito. Tal valor é um pouco superior ao encontrado para o SOPREVA nas previsões sem AD, de 0,71. Na bacia do rio Doce, apresenta NS de 0,52 para o posto com melhor desempenho.

Ressalta-se que estas simulações não foram realizadas nas mesmas situações, com período de dados, discretização ou avaliações. Assim, tais apontamentos não visam o comparativo direto do SOPREVA com estes trabalhos, mas apenas um enquadramento no patamar de desempenho apresentado por eles.

Ainda com o intuito enquadrar o desempenho do SOPREVA frente a outros métodos, Gama e Paiva (2018) avaliaram a utilização de uma Rede Neural Artificial e do SOPREVA para previsões com horizonte de até 48h para a bacia de Guajuvira. Neste caso, foram utilizados o mesmo período e série de dados para avaliação.

Apesar da RNA apresentar um desempenho ligeiramente superior ao SOPREVA para primeiras horas de previsão, este apresentou um menor decaimento do desempenho à medida que aumentou o horizonte das previsões, conforme Figura 23. Além disso, o decaimento do desempenho deu-se de forma mais suave, enquanto que na RNA ocorria de forma oscilatória devido ao modelo possuir uma parcela aleatória na sua concepção e não uma base física. Neste ponto, o SOPREVA se mostra equiparável ao método de RNA, consolidado na previsão hidrológica e em concordância com o discutido por Vrugt et al. (2005) sobre a capacidade de modelos hidrológicos concentrados que utilizam técnicas de assimilação de dados com foco em previsões.

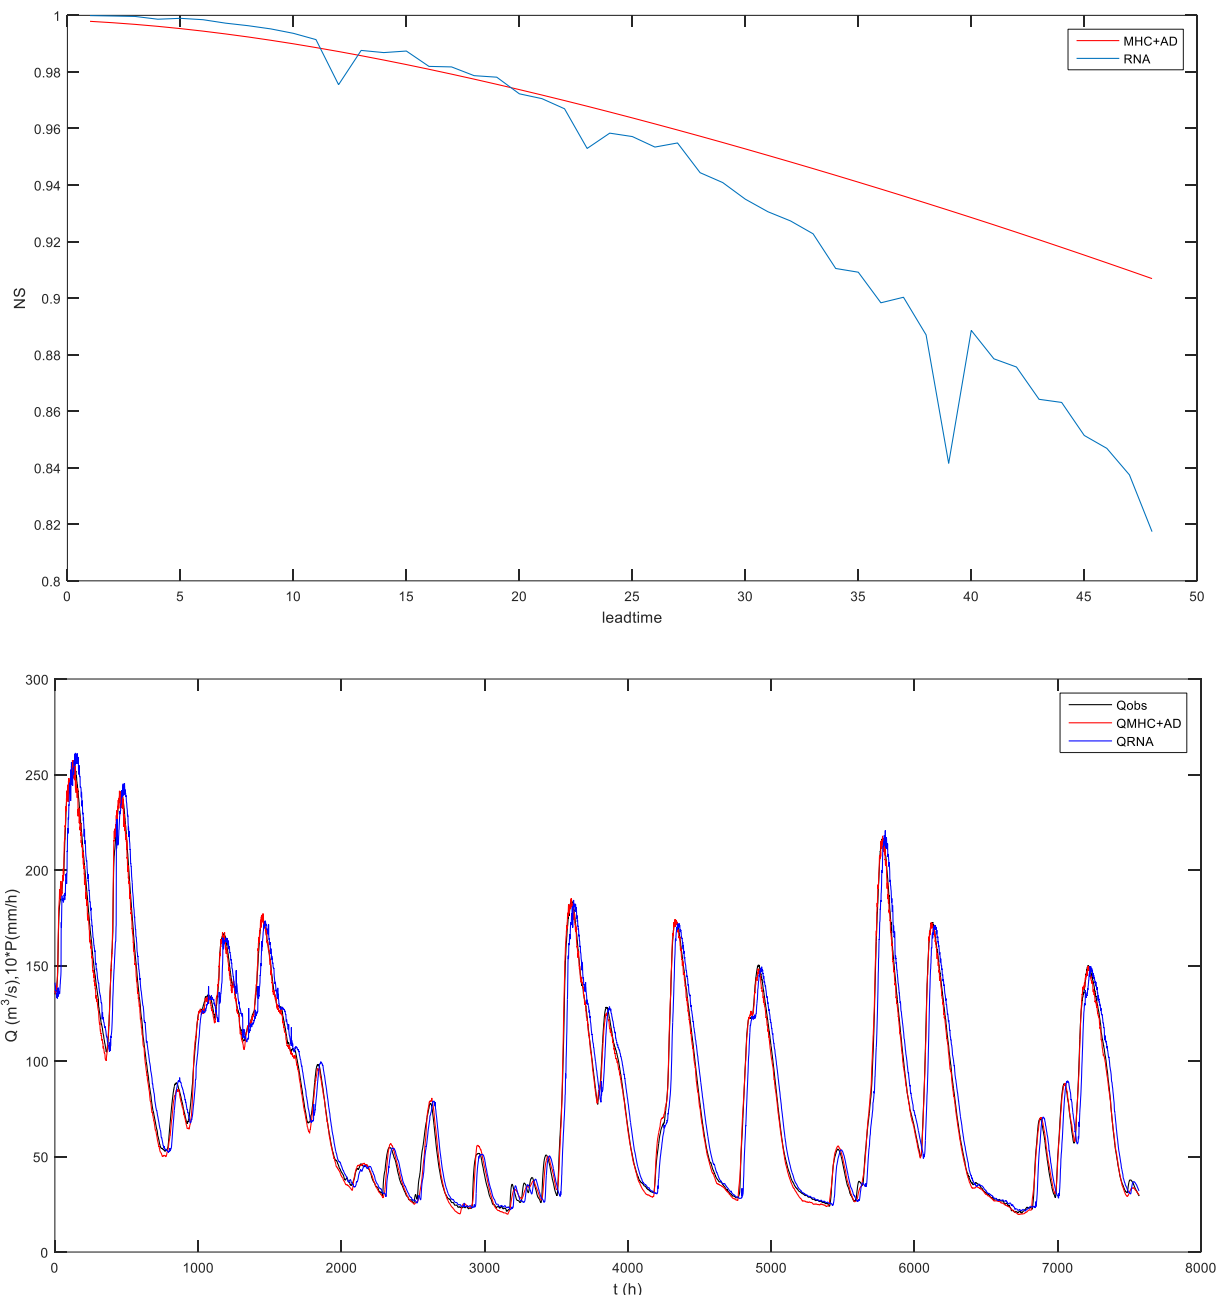


Figura 23 – a) Desempenho nas previsões com horizonte até 48h para a bacia de Guajuvira a partir do SOPREVA (em azul) e de RNA (em vermelho); b) Hidrogramas para vazões previstas com 5h de antecedência.

Fonte: Gama e Paiva (2018)

5.5. PREVISÕES COM ESTIMATIVAS DE CHUVA DO GEFS

5.5.1. Previsão para período contínuo

São apresentados a seguir os resultados oriundos da utilização das estimativas de chuva do modelo GEFS para realização das previsões, realizadas às 00h, com horizonte de até 24h, para todos os dias das séries de dados de cada bacia.

A Figura 24 apresenta um comparativo do desempenho nas previsões, medido através do coeficiente de Nash-Sutcliffe, quando utilizado i) dados de chuva real como estimativa das precipitações futuras; ii) as estimativas do GEFS e; iii) dados de chuva real mas sem utilização de assimilação de dados. Nas linhas em cores claras são apresentados os desempenhos para cada bacia avaliada as cores mais escuras representam a média destes dados. Em preto constam os desempenhos do Sistema com chuva real; em vermelho com as estimativas do GEFS e; em azul com chuva real, mas sem a utilização de assimilação de dados.

Observa-se que o desempenho do Sistema com utilização das estimativas do modelo GEFS aproxima-se bastante do desempenho obtido quando utilizado dados de chuva real. Este fato sugere que o modelo GEFS se apresenta como uma boa fonte de estimativas de precipitação para operacionalização do sistema de previsão. Além disso, mais uma vez é possível observar o ganho obtido com a aplicação da técnica de assimilação de dados sobre o modelo hidrológico concentrado, tornando-o capaz de melhores estimativas em todas as bacias analisadas.

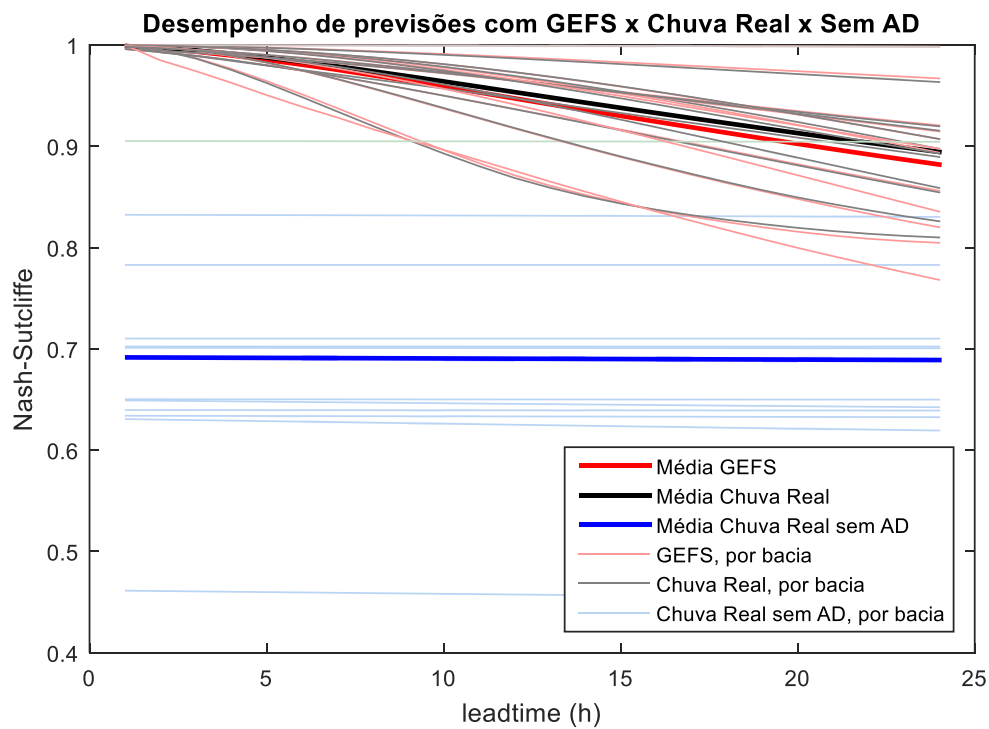


Figura 24 – Desempenho de previsões com utilização de estimativas de precipitação: do GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul).

Sob a possibilidade da aproximação entre o desempenho com estimativas do GEFS e com chuva real estar sendo devido aos períodos secos, onde é mais fácil um modelo climatológico prever a não ocorrência de chuva do que quantificá-la em outras ocasiões, foi gerado um outro gráfico comparativo de desempenho com consideração apenas das vazões acima da Q50 de cada bacia. Os desempenhos são então apresentados na Figura 25.

Em comparação com gráfico anterior, há uma redução nos valores do coeficiente de Nash-Sutcliffe para todas as séries avaliadas. Contudo, o desempenho das previsões com estimativas do GEFS permanece muito próximo do obtido para previsões com chuva real, reforçando o potencial deste modelo como fonte de estimativas de precipitação para sistemas de previsão como o SOPREVA.

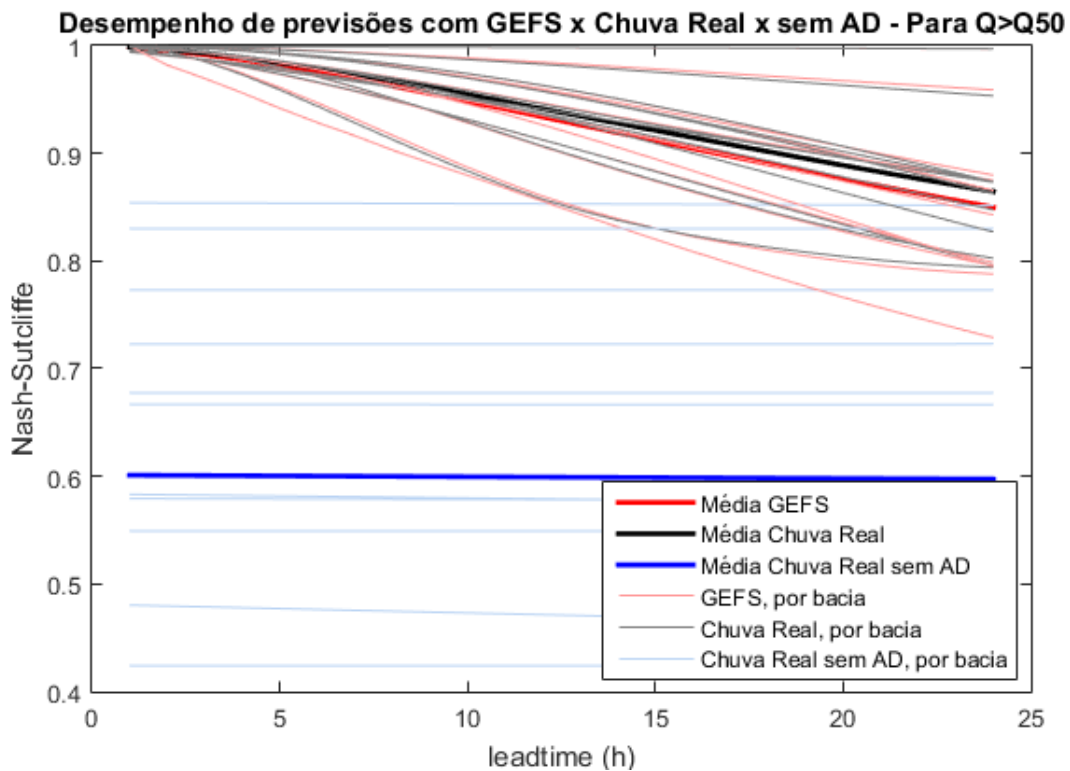


Figura 25 - Desempenho de previsões para vazões acima da Q50. Comparativo entre GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul).

As previsões cujo desempenho é discutido nos dois gráficos acima são realizadas para todo o período, considerando as estimativas do GEFS para um horizonte máximo de 24 horas de forma contínua.

A Figura 26 apresenta uma análise do desempenho para um horizonte de até 7 dias, com previsões sempre realizadas às 00h (momento de geração das estimativas do GEFS) de cada dia da série de dados. Observa-se que para os primeiros momentos de previsão o desempenho do GEFS se assemelha bastante ao desempenho do sistema com chuva real, conforme já havia sido mostrado nas Figura 24 e Figura 25.

Contudo, para horizontes maiores é perceptível a influência da fonte de estimativas de precipitações, de forma que para essas previsões o GEFS supera o modelo sem AD apenas para as 60h iniciais enquanto que as estimativas com chuva real melhoram o desempenho até 95h.




Figura 26 - Comparativo entre GEFS (em vermelho); chuva real (em preto) e; chuva real sem assimilação de dados (em azul) para eventos às 00h e com horizonte de até 168h.

Em seguida são apresentados os hidrogramas com vazões previstas utilizando o modelo GEFS em comparação com as previsões baseadas em chuva real, com e sem assimilação de dados, para horizontes de 05 e 24h, em algumas bacias avaliadas.




Figura 27 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Fazenda Boa Fortuna. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

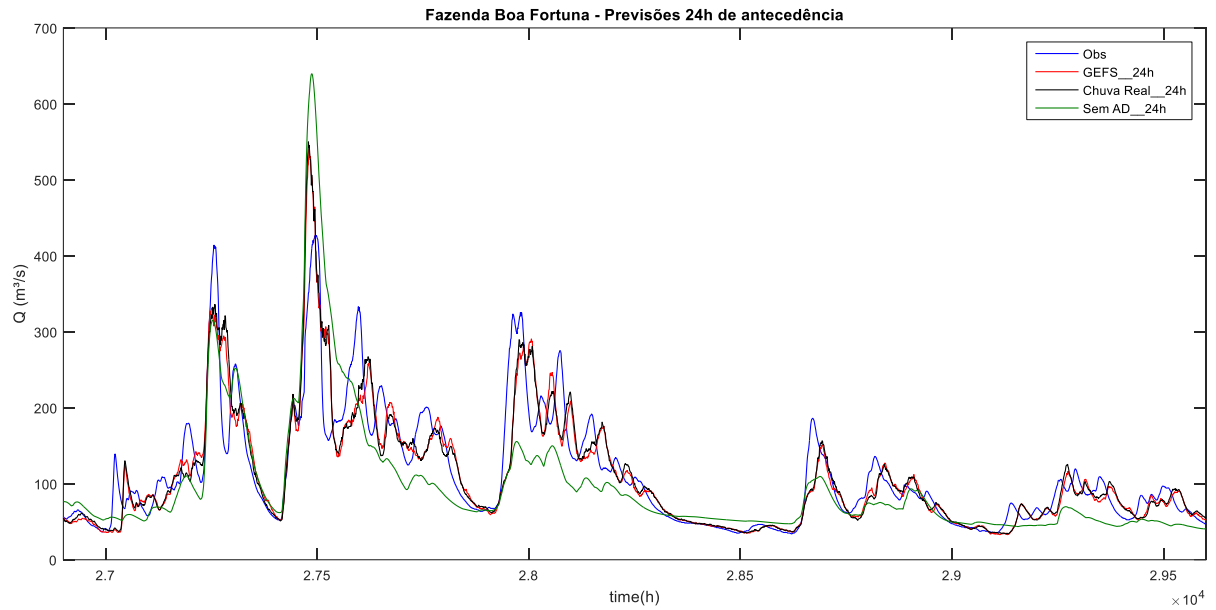


Figura 28 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Fazenda Boa Fortuna. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

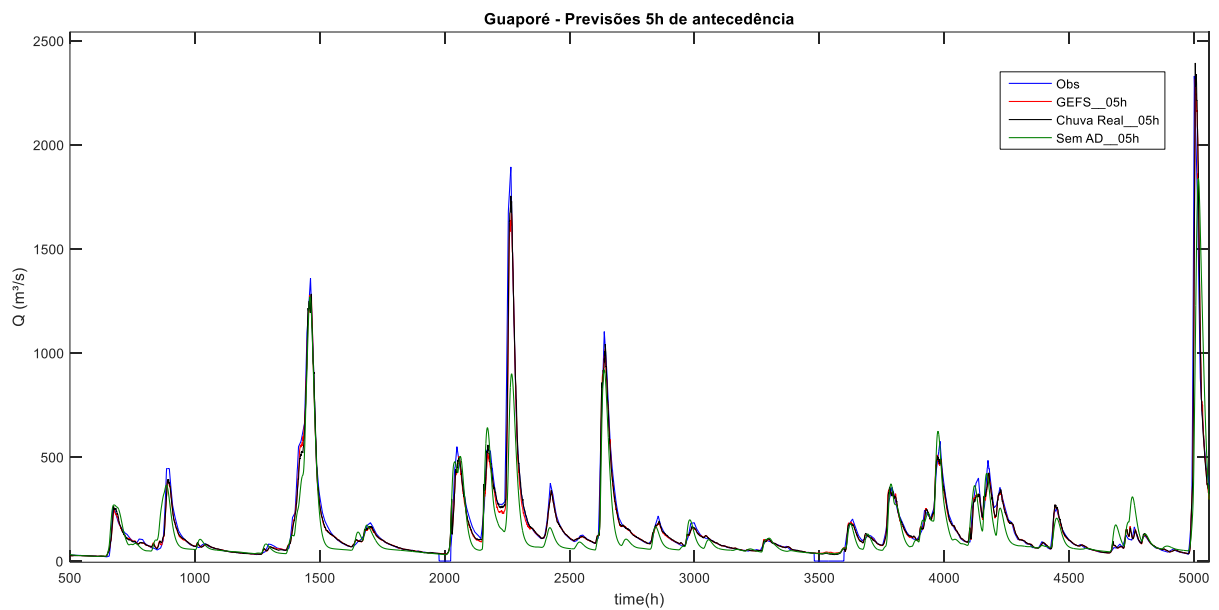


Figura 29 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Guaporé. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

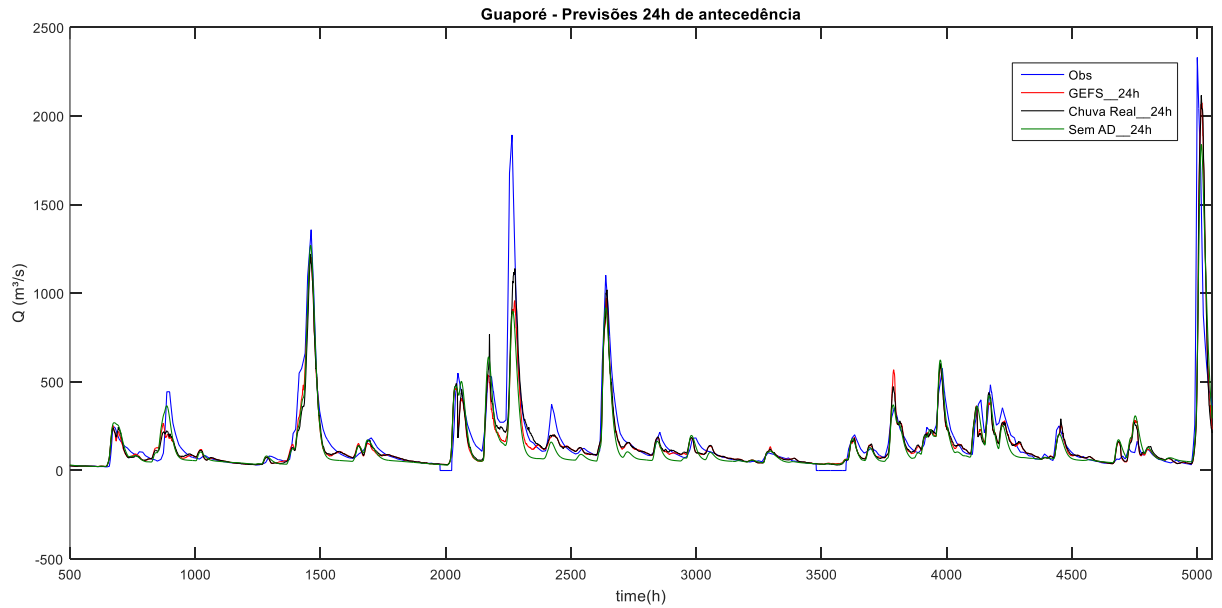


Figura 30 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Guaporé. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

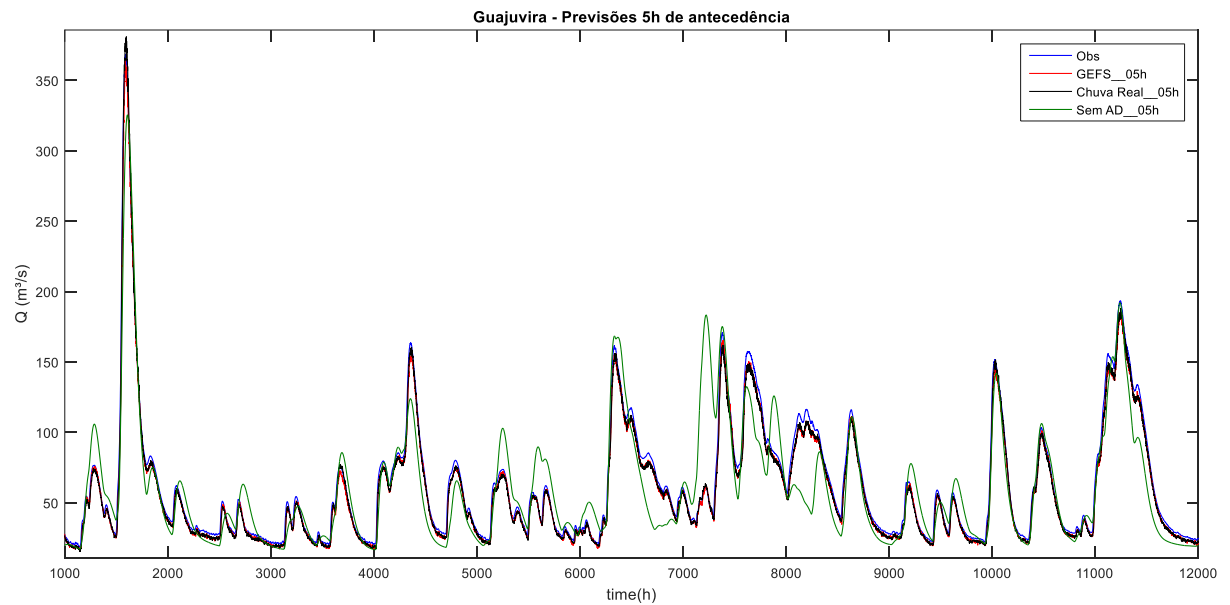


Figura 31 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Guajuvira. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

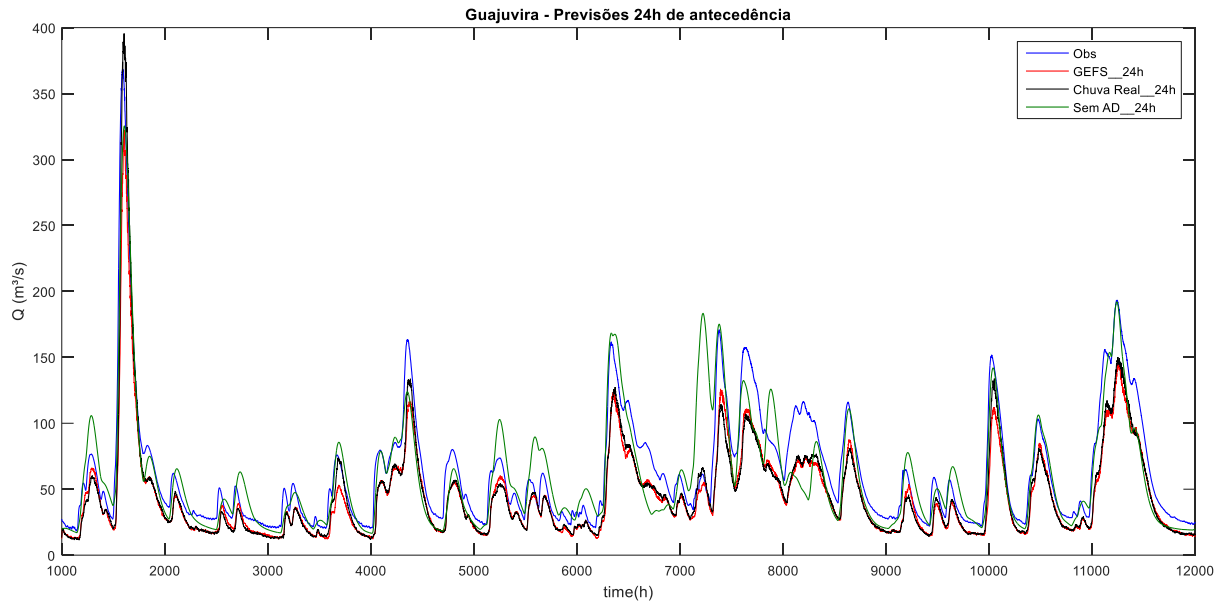


Figura 32 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Guajuvira. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

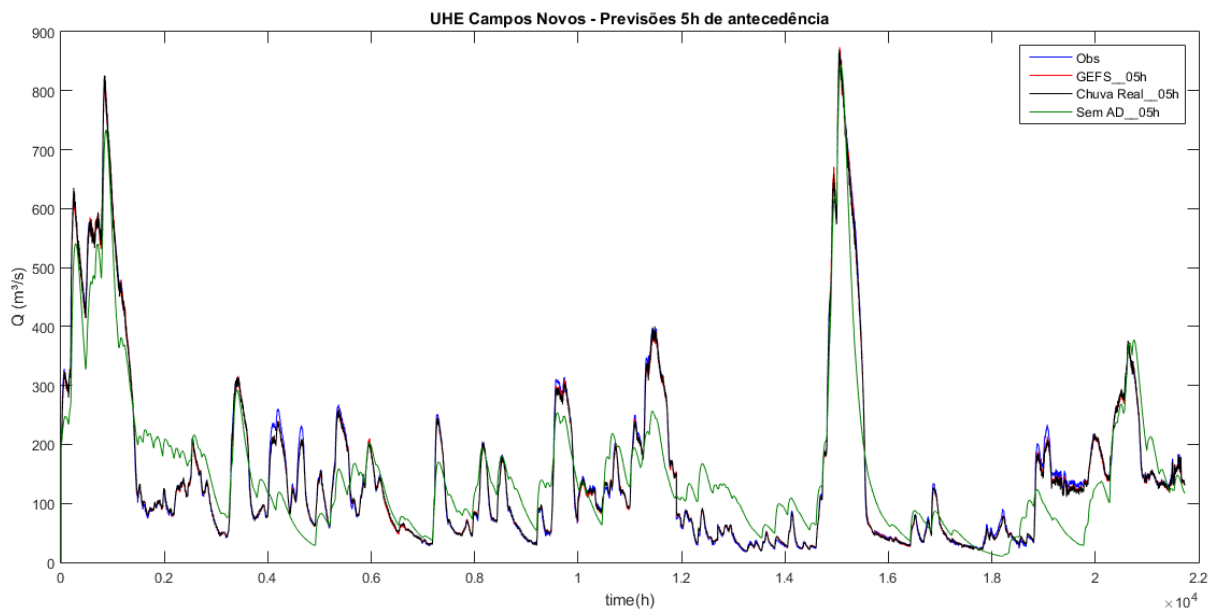


Figura 33 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia UHE Campos Novos. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

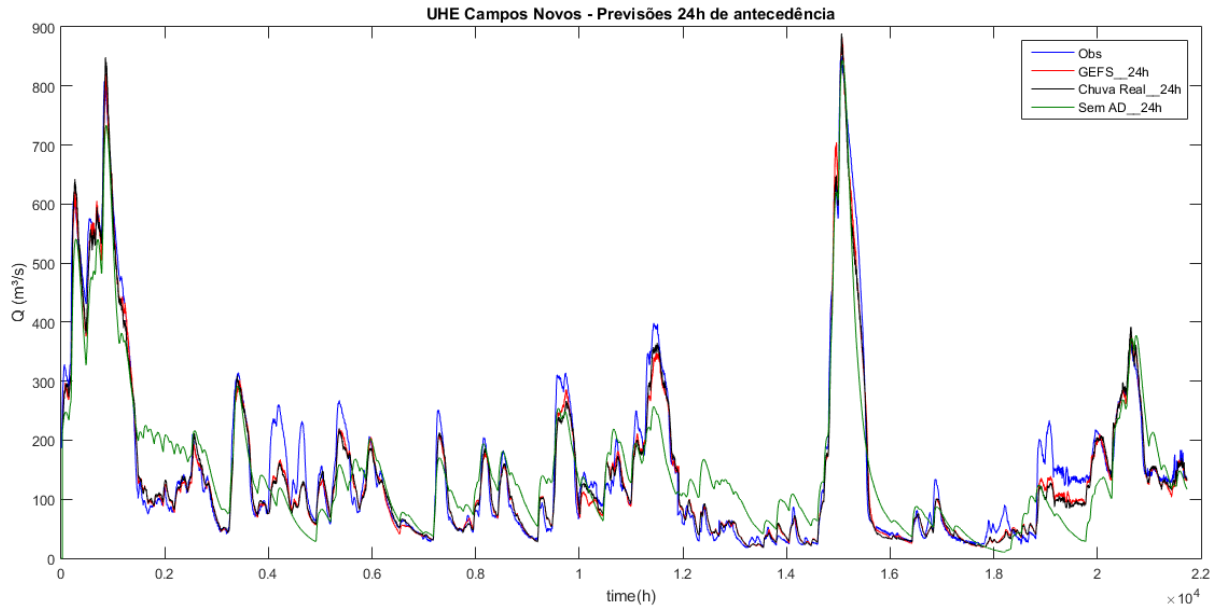


Figura 34 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia UHE Campos Novos. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

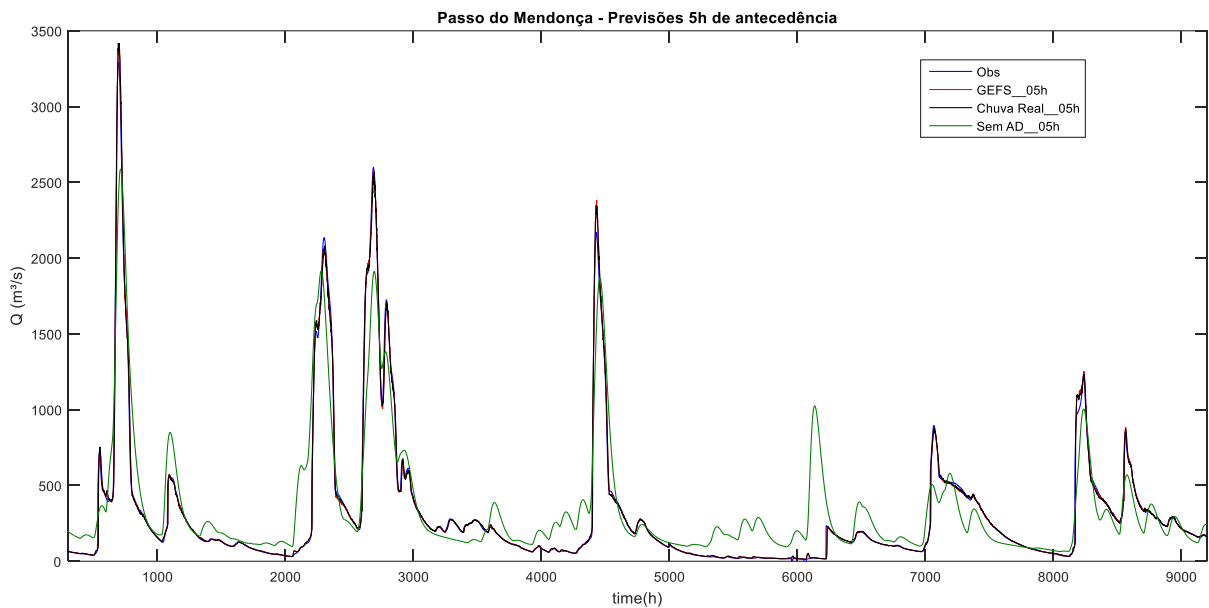


Figura 35 - Hidrogramas de vazões previstas com antecedência de 05h para a bacia Passo do Mendonça. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.




Figura 36 - Hidrogramas de vazões previstas com antecedência de 24h para a bacia Passo do Mendonça. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

5.5.2. Previsão em eventos selecionados

As Figura 37, Figura 38, Figura 39 e Figura 40 apresentam as previsões por conjunto, com 11 membros do GEFS, para quatro eventos selecionados. As previsões têm horizonte de previsão máximo de 168h e o último dado assimilado é a vazão observada no momento de partida da previsão (tempo 0). Em preto são apresentadas as vazões observadas, em vermelho claro encontram-se as vazões previstas para cada membro do conjunto e em vermelho escuro a média dos membros.

Por análise visual dos eventos, nota-se que para o primeiro evento da bacia UHE Campos Novos os membros do conjunto apresentam-se com um pequeno espalhamento durante a subida do hidrograma, indicando poucas incertezas, e com o membro médio bastante próximo das vazões observadas até um horizonte de 50h. Para horizontes maiores é observado um maior espalhamento das previsões dos membros e uma predominância de superestimação das vazões.

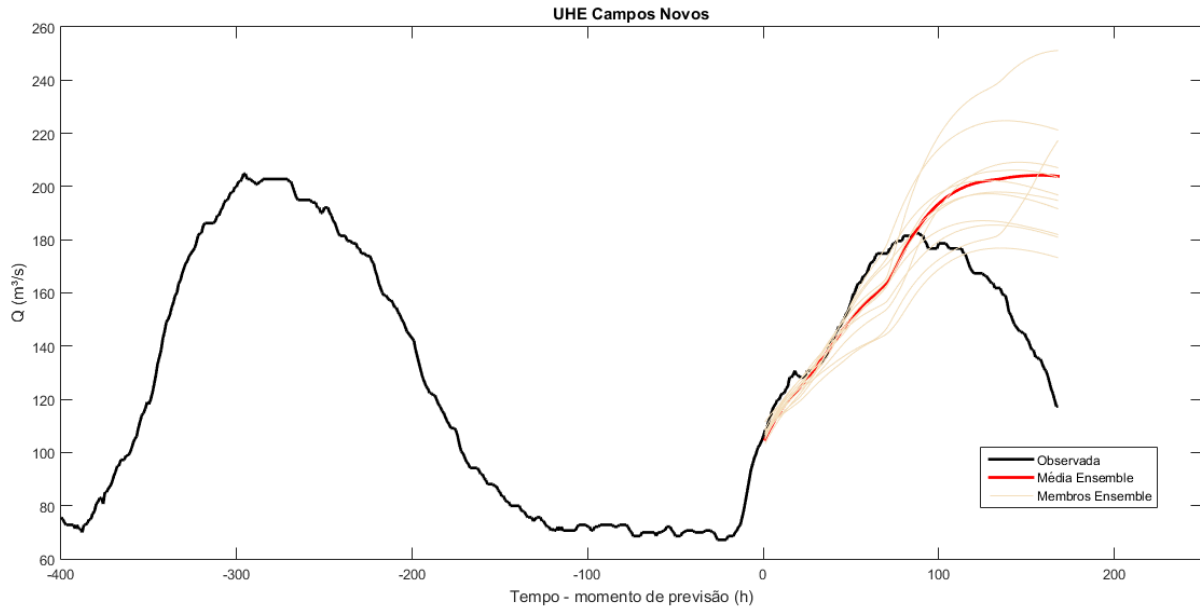


Figura 37 – Previsão por conjunto em evento na bacia UHE Campos Novos em momento logo após início da ascensão do hidrograma.

No evento da bacia Guaporé o momento de partida da previsão ocorre próximo ao pico do hidrograma, gerando previsões para o período de ressecção do hidrograma. É observado um pequeno espalhamento durante todo o período de previsão e uma aproximação dos membros centrais ao hidrograma de vazões observadas.




Figura 38 - Previsão por conjunto em evento na bacia Guaporé em momento próximo ao pico do hidrograma do evento, com previsão para ressecção.

Para o segundo evento da bacia UHE Campos Novos é observado a ocorrência de um espalhamento um pouco maior dos membros, em comparação com os outros eventos avaliados, desde o horizonte de previsão de 30h. Apesar do tempo de pico do evento ser bem aproximado

pelos membros, a maior parte das estimativas, e a média dos membros, subestimam as vazões observadas, havendo apenas um membro que superestima o evento com cerca do dobro da vazão de pico.

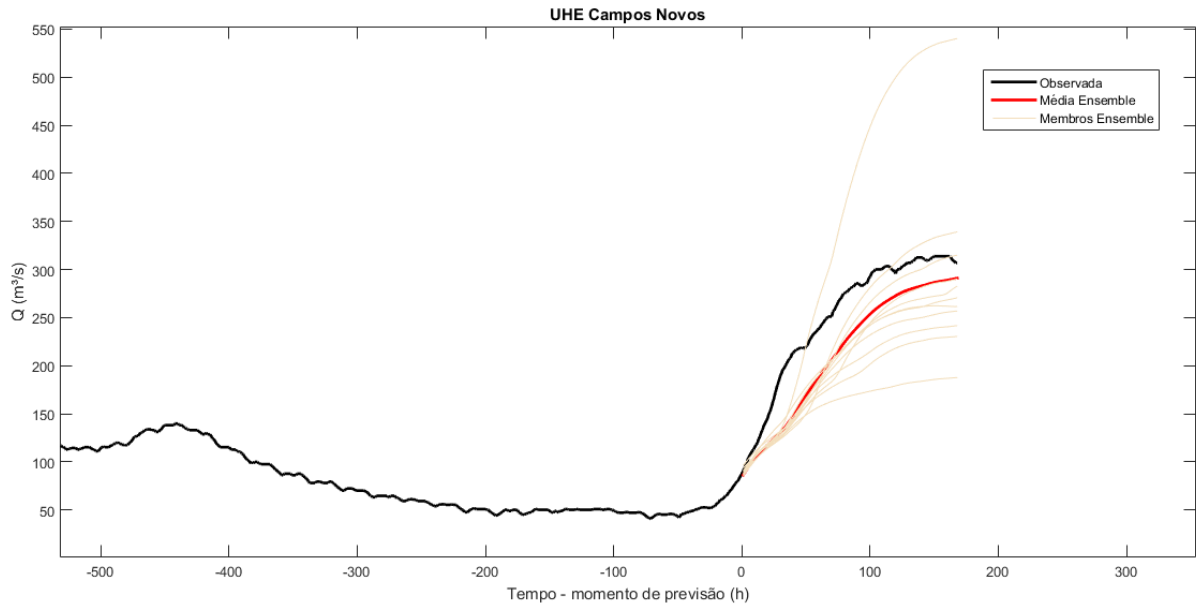


Figura 39 - Previsão por conjunto em evento na bacia UHE Campos Novos em momento de ascensão do hidrograma.

Para o evento da bacia PCH João de Deus é observado um grande espalhamento dos membros desde o instante de partida das previsões. Apesar da superestimativa do evento por parte de alguns membros e da subestimativa por outros, os membros centrais e a média se aproximam aos valores observados. Para estes, contudo, ainda é possível verificar um atraso do pico do evento de aproximadamente 20h.

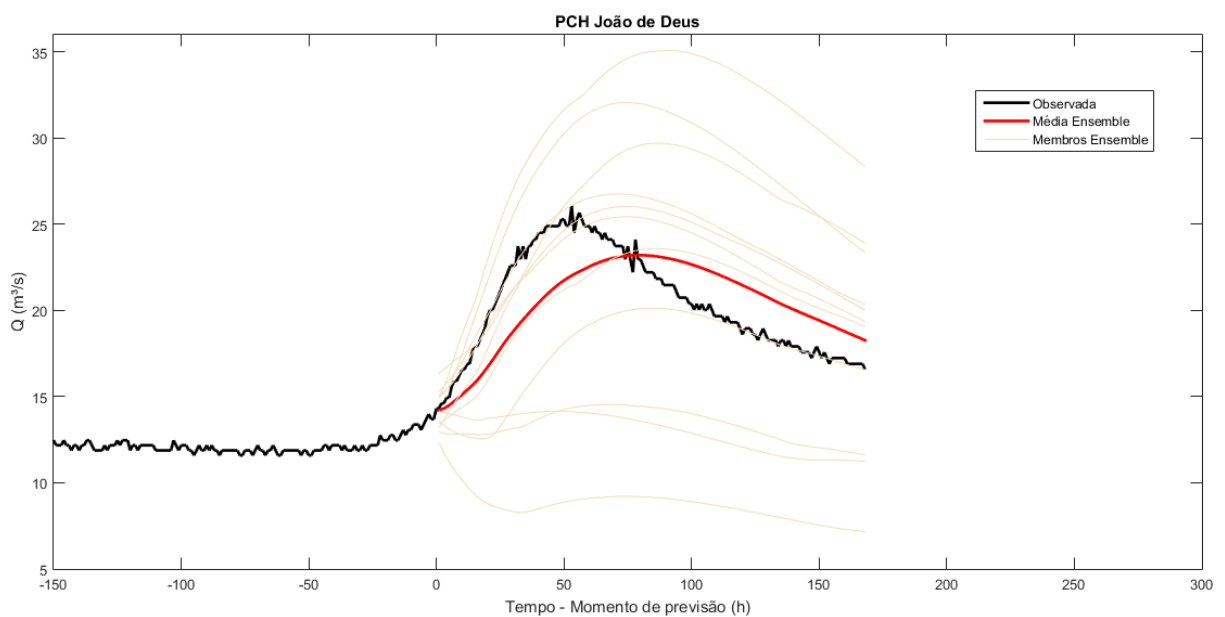


Figura 40 - Previsão por conjunto em evento na bacia PCH João de Deus em momento de ascensão do hidrograma.

A Tabela 10 apresenta o valor do RMSE entre a média dos membros e as vazões observadas no período de previsão para cada um dos eventos. São apresentados também a vazão de pico de cada evento, como parâmetro de magnitude.

Como já observado na análise visual, o evento 2 apresentou o menor erro percentual, relativo à vazão média do evento, para todo o período de 168h previsão. Para o evento 2, o RMSE maior encontrado nas primeiras 24 horas justifica-se por esse ser uma previsão para a parte de recessão do hidrograma, partido de seu pico. Contudo, é destacado o baixo erro relativo para este evento. Destaca-se os pequenos valores de erros encontrados para as primeiras 24 horas de previsão, demonstrando o potencial do Sistema e da previsão por conjunto na previsão destes eventos.

Tabela 10 – Desempenho das previsões por conjunto medido através do RMSE entre a média dos membros e valores observados para horizontes de até 24 e para todo o período de previsão de 168h.

Evento	Momento da previsão	RMSE 1-24h (m³/s)	RMSE 1-168h (m³/s)	RMSE 1-24h (%)	RMSE 1-168h (%)	Qpico (m³/s)
1 – UHE Campos Novos	04/09/2016 17h00	1.04	21.17	0.85	11.55	182.43
2 – Guaporé	19/09/2009 8h00	28.71	13.16	9,66	8.92	367.15
3 – UHE Campos Novos	31/01/2016 17h00	2.70	45.16	3.99	16.39	313.77
4 – PCH João de Deus	04/06/2016 10h00	1.67	2.16	9.68	11.38	20.75

6. CONCLUSÕES E RECOMENDAÇÕES

No presente trabalho foi proposto e avaliado um sistema simplificado de previsão de vazões, baseado em técnicas avançadas de modelagem de base física, assimilação de dados e previsão meteorológica, porém de fácil implementação e operacionalização.

Foram verificados os desempenhos do Sistema utilizando chuva real e estimativas de precipitação geradas por um modelo meteorológico, o GEFS, a fim de primeiramente avaliar a estrutura do SOPREVA e, depois, verificar a performance do Sistema para possível uso operacional. Além disso, o desempenho foi avaliado em doze diferentes bacias hidrográficas brasileiras (com áreas entre 955 a 226000 km² e Q50 entre 9.15 e 2954 m³/s), com objetivo de discutir e analisar a aplicabilidade do Sistema em diferentes localidades e diante características hidrológicas distintas. Por fim, avaliou-se o SOPREVA na previsão por Ensemble de eventos específicos ocorridos em algumas das bacias analisadas, sob intuito de verificar a possibilidade de utilizar operacionalmente tal sistema com previsões por conjunto. Diante dos resultados obtidos foi permitido as seguintes considerações a respeito das questões envolvidas:

- A técnica de assimilação (EnKF) aplicada neste trabalho forneceu ao Sistema melhor desempenho em todas as análises realizadas;
- Quando avaliado com chuva real, o uso da assimilação de dados melhorou a performance média do sistema para as previsões com horizonte de até 5 dias e uma ponderação do desempenho pelo tempo de pico de cada bacia sugere a indicação de aplicação do Sistema para um horizonte de previsão máximo de pelo menos 1,5 vezes o tempo de pico;
- O SOPREVA conseguiu apresentar bom desempenho quando utilizado com dados com discretização diária, demonstrando a possibilidade de aplicação do Sistema para esses casos, e a assimilação de dados também melhorou o desempenho para as previsões diárias;
- Quanto às características das bacias, as maiores correlações de desempenho se deram com as características i) área; ii) tempo de pico e; iii) coeficiente de assimetria dos hidrogramas. De forma que para bacias com maiores áreas, maiores tempos de picos e menores coeficientes de assimetria se obteve os melhores desempenhos. Contudo, estas correlações devem ser ponderadas pelo fato de estarem sendo avaliadas bacias grandes em previsões de curto prazo;
- A avaliação comparativa entre o desempenho do SOPREVA e outros modelos de previsão (como RNA ou MGB-IPH), feito para algumas das bacias estudadas, apresenta o Sistema proposto com um desempenho equiparável e com potencial para avaliação no uso operacional nos horizontes de previsão avaliados. Ressalta-se que o desempenho obtido por

este sistema não substitui as informações fornecidas e a performance obtida por sistemas com modelos hidrológicos distribuídos;

- Estimar os erros das variáveis de estado do modelo, para consideração no método de assimilação de dados, a partir de análise de sensibilidade dos erros de forma individual, para cada variável por vez, mostrou-se um método eficiente mediante manutenção dos resultados a partir de análise de sensibilidade conjunta, para as diferentes variáveis;

- Ainda quanto às estimativas de erros das variáveis de estado, foi verificado maior sensibilidade do desempenho nas previsões quando alterado os erros nas variáveis precipitação, evapotranspiração e volume de água armazenado no solo, podendo isto estar associado à importância de tais variáveis no processo hidrológico ou a maiores incertezas nas estimativas;

- O aumento do número de membros no conjunto para o método de assimilação de dados, EnKF, não necessariamente resulta em melhores desempenhos. Além disso, o custo computacional resultante apoia a ideia de definição de um número de membros inferior. A partir da análise de sensibilidade realizada, o número de membros variou de 20 a 200 para as doze bacias avaliadas, mediante consideração do desempenho e tempo de simulação;

- Para o primeiro dia de previsão, a performance do sistema com utilização de estimativas de precipitação geradas pelo modelo GEFS apresentou resultados próximos aos obtidos com utilização de chuva real (mesmo quando avaliado apenas para estimativas superiores à Q50). Para estes casos, a assimilação de dados também melhorou o desempenho médio do SOPREVA, entre as bacias analisadas, para todo o horizonte de 24h avaliado;

- Para eventos ocorridos às 00h (momento de geração das estimativas do GEFS), as estimativas com o GEFS apresentaram desempenho próximo ao obtido com chuva real para as primeiras horas do horizonte de previsão. Contudo, superou as estimativas do modelo sem AD até o horizonte de 60h, enquanto que o modelo com real superou para até 95h;

- O SOPREVA apresentou-se como uma potencial ferramenta para geração de previsões por conjunto ao gerar previsões a partir dos membros do Ensemble do GEFS, principalmente para os primeiros dias de previsão. Para os eventos avaliados foi possível uma percepção do espalhamento das estimativas meteorológicas em alguns pontos e uma avaliação de previsões estatisticamente mais prováveis pela predominância em diferentes membros.

Diante destes apontamentos, o SOPREVA apresenta-se como uma ferramenta alternativa para a previsão de vazões, sobretudo sobre sua facilidade de implementação e desempenho equiparável a outros sistemas. Tal simplicidade de implementação também apontam o Sistema proposto como uma ferramenta versátil para outras investigações

hidrológicas e de assimilação de dados. Em continuidade a este trabalho, é recomendada a avaliação do Sistema em outras bacias; a implementação e análise do desempenho deste de forma operacional e; a avaliação de possíveis melhorias no modelo.

7. REFERÊNCIAS BIBLIOGRÁFICAS

Alfieri, L.; Burek, P.; Dutra, E.; Krzeminski, B.; Muraro, D.; Thielen, J.; Pappenberger F. (2013). GloFAS – global ensemble streamflow forecasting and flood early warning. *Hydrol. Earth Syst. Sci.*, vol.17, pg. 1161-1175.

Anderson, J. L., 1996: A method for producing and evaluating probabilistic forecasts from ensemble model integrations. *J. Climate*, 9, 1518–1530.

Andreadis, K. M.; Lettenmaier, D. P. (2006). Assimilating remotely sensed snow observations into a macroscale hydrology model, *Adv. Water Res.*, 29, pg. 872–886.

Brezková, L.; Starý, M.; Dolezal, P. (2010). The real-time stochastic flow forecast. *Soil Water Resour.*, vol. 5 (2), pg. 49–57.

BUIZZA, R. (2008). The value of probabilistic prediction. *Atmos. Sci. Lett.*, v. 9, p. 36–42.

Buizza, R.; Hollingsworth, A.; Lalauette F.; Ghelli, (1999). A. Probabilistic predictions of precipitation using the ECMWF Ensemble Prediction System. *Weather and Forecasting*, v. 14, p. 168–189.

Carpenter, T. M.; Georgakakos, K.P. (2006). Intercomparison of lumped versus distributed hydrologic model ensemble simulations on operational forecast scales. *Journal of Hydrology*, vol. 329, pg. 174-185.

Chen, H.; Yang, D.; Hong, Y.; Gourley, J. J.; Zhang, Y. (2013). Hydrological data assimilation with the Ensemble Square-Root-Filter: Use of streamflow observations to update model states for real-time flash flood forecasting, *Advances in Water Resources* 59, pg. 209 – 220.

Clark, M.P.; Rupp, D.E.; Woods, R.A.; Zheng, X.; Ibbitt, R.P.; Slater, A.G.; Schmidt, J.; Uddstrom, M.J. (2008). Hydrological data assimilation with the ensemble Kalman filter: Use of streamflow observations to update states in a distributed hydrological model. *Advances in Water Resources* 31, pg. 1309–1324.

Cloke, H.L.; Pappenberger, F. (2009). Ensemble flood forecasting: A review. *Journal of Hydrology*, v.375, n. 3–4, p.613–626.

Collischonn, W. et al. (2007). The MGB-IPH model for large-scale rainfall—runoff modelling. *Hydrological Sciences Journal*, vol. 52, n. 5, pg. 878-895.

Collischonn, W.; Tucci, C. E. M. (2001). Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*, vol. 6, n. 2.

- Cuo L., Pagano T. C., Wang, Q.J. (2011). A review of quantitative precipitation forecasts and their use in short- to medium-range streamflow forecasting. *Journal of Hydrometeorology*, v. 12, p. 713–728.
- Deb, K.; Pratap, A.; Agarwal, S.; Meyarivan, T. (2002). A fast and elitist Multiobjective Genetic Algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, vol. 6, nº. 2, pg. 182 – 197.
- Diniz, L. S. (1999). Calibração de modelos hidrológicos. In: Galvão, C. O.; Valença, M. J. S. 1999. *Sistemas inteligentes*. Porto Alegre: UFRGS – ABRH.
- Duan, Q. (2005). Shuffled Complex Evolution Method. MATLAB Central File Exchange.
- Duan, Q.; Sorooshian, S.; Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, vol. 28, nº 4. pg. 1015-1031.
- Dumedah, G. e Coulibaly, P. (2013). Evaluating forecasting performance for data assimilation methods: The ensemble Kalman filter, the particle filter, and the evolutionary-based assimilation, *Advances in Water Resources* 60 (0), pg.47 – 63.
- Elsafi, S. H. (2014). Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan. *Alexandria Eng. J.*, vol. 53 (3), pg. 655-662.
- Evensen, G. (2003). The Ensemble Kalman Filter: theoretical formulation and practical implementation *Ocean Dynamics*. 53, pg. 343–367.
- Evensen, G. (2004). Sampling strategies and square root analysis schemes for the EnKF, *Ocean Dynam.*, 54, pg. 539–560.
- Fan, F. M. (2015b). Previsão por conjunto de vazões afluentes a reservatórios em grandes bacias hidrográficas brasileiras. Tese de Doutorado. Tese em Recursos Hídricos e Saneamento Ambiental – UFRGS, Porto Alegre – RS.
- Fan, F. M.; Collischonn, W.; Quiroz, K. J.; Sorribas, M.V.; Buarque, D. C.; Siqueira, V.A. (2015). Flood forecasting on the Tocantins River using ensemble rainfall forecasts and real-time satellite rainfall estimates. *Journal of Flood Risk Management*, vol. 9, pg. 278-288.
- Fan, F. M.; Meller, A.; Collischonn, W. (2014). Incorporação de filtro numérico de separação de escoamento na assimilação de dados para previsão de vazões utilizando modelagem hidrológica. *Revista Brasileira de Recursos Hídricos*, vol. 20, nº 2, pg. 472-483.
- Fan, F. M.; Paiva, R.C.D.; Collischonn, W. (2016). Hydrological Forecasting Practices in Brazil, in *Flood Forecasting – A Global Perspective*. ch. 2, pg. 41-66.
- Gama, C. H. A.; Paiva, R. C. D. (2018). Validação de um sistema de previsão de vazões baseado em modelo hidrológico concentrado com assimilação de dados. *Anais do XIV Simpósio de Recursos Hídricos do Nordeste*, ABRH, Maceió – AL.

Gama, C. H. A.; Pedrollo, O. C. (2018). Previsão de níveis na bacia do rio Mundaú a partir de Redes Neurais Artificiais. Anais do XIV Simpósio de Recursos Hídricos do Nordeste, ABRH, Maceió – AL.

Guilhon, L. G. F.; Rocha, V. F.; Moreira, J. C. (2007). Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. Revista Brasileira de Recursos Hídricos, vol. 12 (3), pg. 13-20.

Gupta, H. V. et al. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. Journal of Hydrology, v. 377, n. 1-2, pg. 80-91.

Hamill T. M.; Bates G. T.; Whitaker J. S.; Murray D. R.; Fiorino M.; Galarneau T. J. Jr., Zhu Y.; Lapenta W. (2013). NOAA's secondgeneration global medium-range ensemble reforecast data-set. Bulletin of the American Meteorological Society, vol. 94, pg. 1553–1565.

Hamill T. M.; S. J. Colucci, 1996. Random and systematic error in NMC's short-range Eta ensembles. Preprints, 13th Conf. on Probability and Statistics in the Atmospheric Sciences, San Francisco, CA, Amer. Meteor. Soc., 51–56.

Hamill T. M.; S. J. Colucci. (1997). Verification of Eta-RSM short-range ensemble forecasts. Mon. Wea. Rev., 125, 1312–1327.

Harrison, M. S. J., D. S. Richardson, K. Robertson, and A. Woodcock, 1995: Medium-range ensembles using both the ECMWF T63 and unified models—An initial report. UKMO Tech. Rep. 153, 25 pp.

Hirpa, F. A.; Salamon, P.; Alfieri, L.; Pozo, J. T.; Zsoter, E.; Pappenberger, F. (2016). The effect of reference climatology on global flood forecasting. Journal of Hydrometeorology, vol. 17, pg. 1131-1145.

Katzfuss, M.; Stroud, J.R.; Wikle, C.K. (2016). Understanding the Ensemble Kalman Filter. The American Statistician, vol. 70 (4), pg. 350-357.

Kitanidis, P. K.; Bras, R. L. (1980). Real time forecasting with a conceptual hydrologic model 2: applications and results. Water Resources Research, v. 16, n. 6, pg. 1034-1044.

Lahoz, W., Khattatov, B. & Ménard, R. (2010). Data Assimilation: Making Sensing of Observation. Verlag Berlin Heidelberg: Springer.

Lettenmaier, D.P.; Wood, E.F. (1993). Hydrological Forecasting, Chapter 26 in Handbook of Hydrology. (D. Maidment, ed.), McGraw-Hill. D.P.

Liu, Y.; Gupta, H. V. (2007). Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. Water Resources Research., vol. 43.

Liu, Y.; Weerts, A. H.; Clark, M.; Franssen, H. J. H.; Kumae, S.; Moradkhani, H.; Seo, D. J.; Schwanenberg, D.; Smith, P.; Van Dijk, A. I. J. M.; Van Velzen, N.; He, M.; Lee, H.; Noh, S. J.; Rakovec, O.; Restrepo, P. (2012). Advancing data assimilation in operational hydrologic forecasting: progresses, challenges, and emerging opportunities. *Hydrology and earth system sciences*, vol. 16, pg. 3863- 3887.

Lopes, V. A. R. (2015). Modelagem hidrológica integrada da bacia hidrográfica da laguna dos patos e seus complexos lagunares usando o modelo MGB-IPH com propagação inercial de vazões. Trabalho de Conclusão de Curso. Graduação em Engenharia Ambiental – UFRGS, Porto Alegre – RS.

Meller, A.; Collischonn, W.; Bravo, J. M.; (2012). Assimilação de Dados de Vazão na Previsão de Cheias em Tempo-Real com o Modelo Hidrológico MGB-IPH. *Revista Brasileira de Recursos Hídricos*, 17 (3), pg. 209-224.

Monte, B. E. O; Costa, D. D.; Chaves, M. B.; Magalhães, L. O.; Uvo, C. B. (2016). Modelagem hidrológica e hidráulica aplicada ao mapeamento de áreas inundáveis. *Revista Brasileira de Recursos Hídricos*, vol. 21 (1), pg. 152-167.

Moraes, M. A. E.; Santos Neto, L. A.; Pimentel, A.; Brown, V. L. R. (2017). GloFAS as a flood alert system in Acre civil defense: performance analysis. JRC Science Hub. <<http://globalfloods.jrc.ec.europa.eu/case-studies/case-study-acre/>>.

Nash, J.E.; Sutcliffe, J.V. (1970). River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology*, vol. 10, pg. 282-290.

Nijssen B; Lettenmaier D.P. (2004). Effect of precipitation sampling error on simulated hydrological fluxes and states: Anticipating the Global Precipitation Measurement satellites. *Journal Geophys. Res.* 109: D02103.

Paiva, R. C. D.; Collischonn, W.; Bonnet, M. P.; Gonçalves, L. G. G.; Calmant, S.; Getirana, A.; Silva, J. Santos. (2013). Assimilating in situ and radar altimetry data into a largescale hydrologic-hydrodynamic model for streamflow forecast in the Amazon. *Hydrol. Earth Syst. Sci.*, 17, pg. 2929–2946.

Paiva, R. C. D.; Collischonn, W.; Buarque, D. C. (2013b). Validation of a full hydrodynamic model for large-scale hydrologic modelling in the Amazon. *Hydrological Processes*, vol. 27, n. 3, pg. 333-346.

Paz, A. R.; Collischonn, W.; Tucci, C. E. M.; Clarke, R. T.; Allasia, D. (2007). Data Assimilation in a large-scale distributed hydrological model for medium-range flow forecasts. In: *PROCEEDINGS OF SYMPOSIUM HS2004 AT IUGG 2007*, Perugia. Perugia: IAHS, 2007. p.471-478.

Reichle, R. H., 2008. Data assimilation methods in the Earth sciences. *Advances in Water Resources*, Volume 31, pg. 1411-1418.

- Sene, K. (2010). *Hydrometeorology: Forecasting and Applications*. Publisher: Springer, 1 edition, 366 p.
- Seshadri, A. (2009). NSGA-II: A multi-objective optimization algorithm. MATLAB Central File Exchange.
- Shah, R. D.; Mishra, V. (2016). Utility of Global Ensemble Forecast System (GEFS) reforecast for medium-range drought prediction in India. *Journal of Hydrometeorology*, vol. 17, pg. 1781-1800.
- Siqueira, V. A. (2015). *Previsão de cheias por conjunto em curto a médio prazo: bacia do Taquari-Antas/RS*. Dissertação de Mestrado. Dissertação em Recursos Hídricos e Saneamento Ambiental – UFRGS, Porto Alegre – RS.
- Siqueira, V. A.; Paiva, R. C. D.; Fleischmann, A. S.; FAN, F. M.; Ruhoff, A. L.; Pontes, P. R. M.; Paris, A.; Calmant, S.; Collischonn, W. (2018). Toward continental hydrologic-hydrodynamic modeling in South America. *Hydrology and Earth System Sciences*, v. 22, p. 4815-4842.
- Sorooshian, S.; Gupta, V. K. (1995) Model calibration In: Singh, V. J. (editor) *Computer models of watershed hydrology*. Water Resources Publications, Highlands Ranch. 1130 p.
- Talagrand, O., R. Vautard, and B. Strauss, 1997: Evaluation of probabilistic prediction systems. *Proceedings, ECMWF Workshop on Predictability, ECMWF*, 1–25.
- Todini, E. (1996). The ARNO rainfall—runoff model. *Journal of Hydrology*, vol. 175, pg. 339-382.
- Tucci, C. E. (2005). *Modelos hidrológicos; Colaboração da Associação Brasileira de Recursos Hídricos/ABRH; 2ª ed.*, Porto Alegre: Editora da UFRGS.
- Tucci, C. E.; Clarke, R. T.; Collischonn, W.; Dias, P. L. S.; Oliveira, G. S. (2003). Long-term flow forecasts based on climate and hydrologic modeling: Uruguay River basin. *Water Resources Research*, vol. 39 (7).
- Veintimilla-Reyes, J.; Cisneros, F.; Vanegas, P. (2016). Artificial neural networks applied to flow prediction: a use case for the Tomebamba River. *Proc Eng.*, vol. 162, pg. 153–161.
- Vrugt, J. A.; Gupta, H. V.; Ó Nualláin, B.; Bouten, W. (2005). Real-Time data assimilation for operational ensemble streamflow forecasting. *Journal of Hydrometeorology*, vol. 7, pg. 548-565.
- Weerts, A. H.; El Serafy, G. Y. H. (2006). Particle filtering and ensemble Kalman filtering for state updating with hydrological conceptual rainfall-runoff models. *Water Resources Research* 42 (9).
- Xavier, A.C.; King, C.W.; Scalon, B.R. (2015). Daily gridded meteorological variables in Brazil (1980–2013). *Int. J. Climatol.* 36, pg. 2644–2659.

8. APÊNDICE

8.1. ESTIMATIVA DOS ERROS DAS VARIÁVEIS DE ESTADO – ANÁLISE DE SENSIBILIDADE

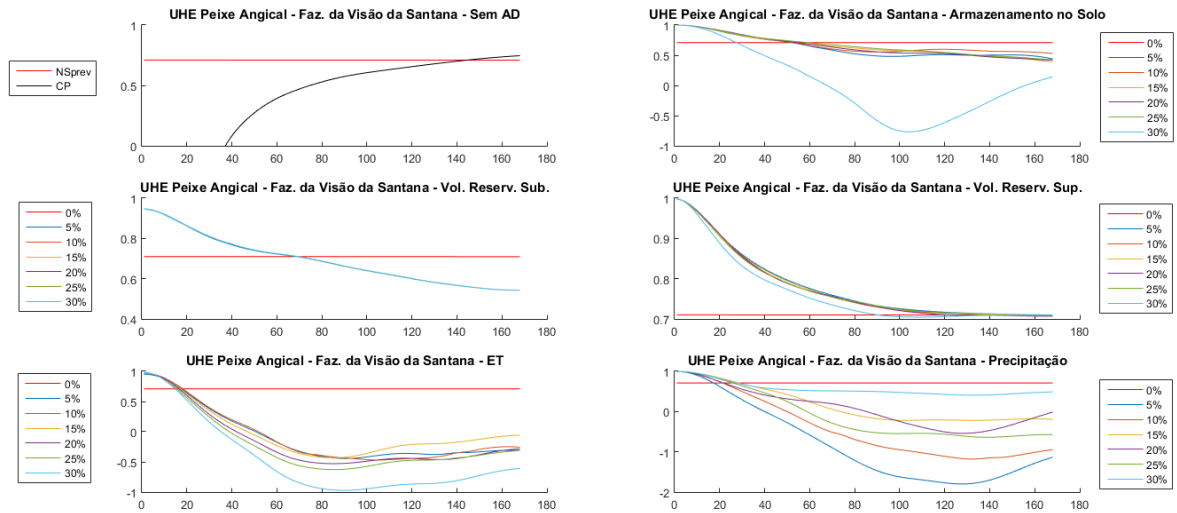


Figura 1 – Análise de sensibilidade das estimativas de erros das variáveis de estado em UHE Peixe Angical

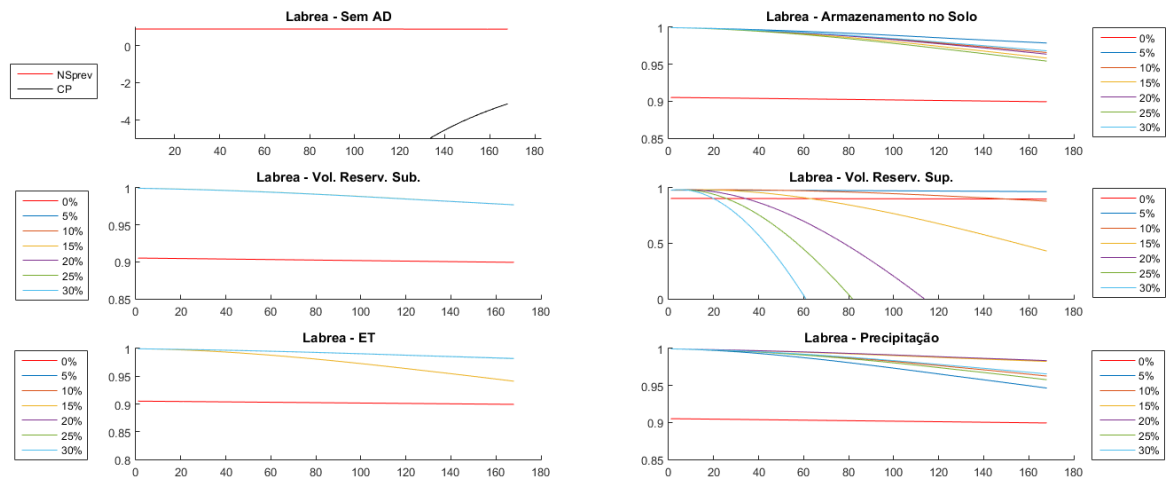


Figura 2 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Labrea

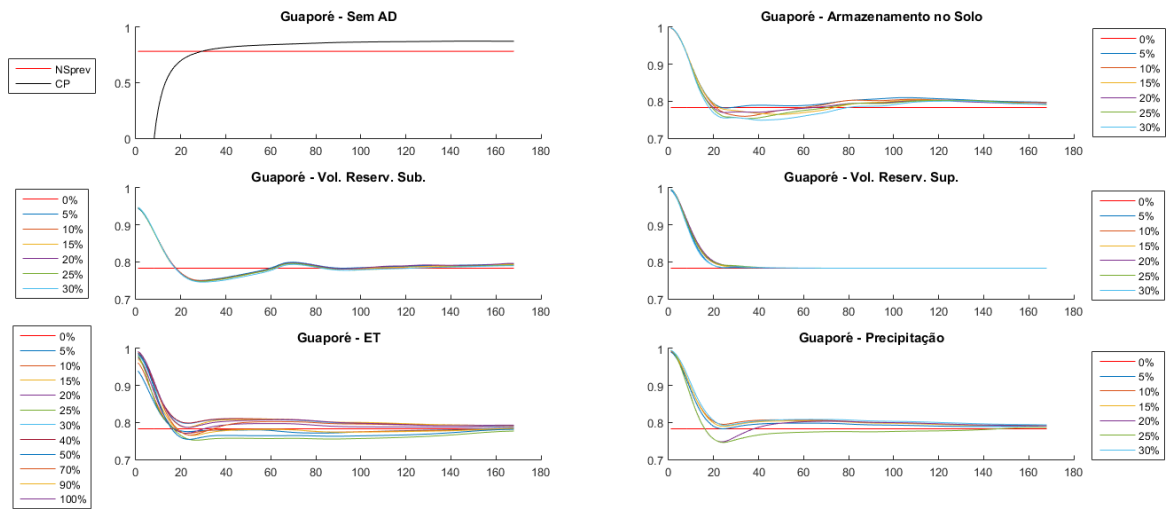


Figura 3 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Guaporé

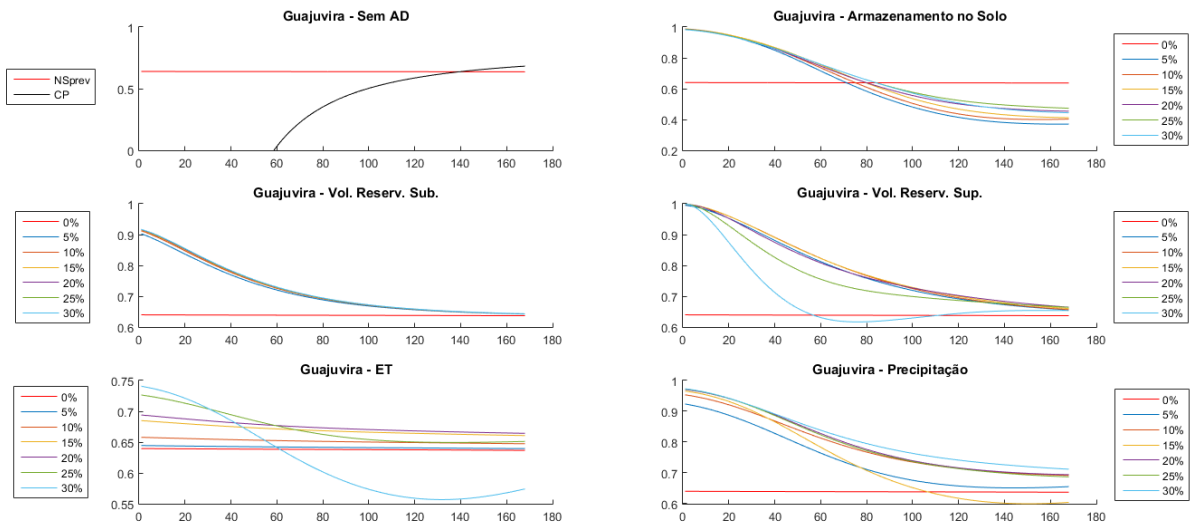


Figura 4 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Guajuvira

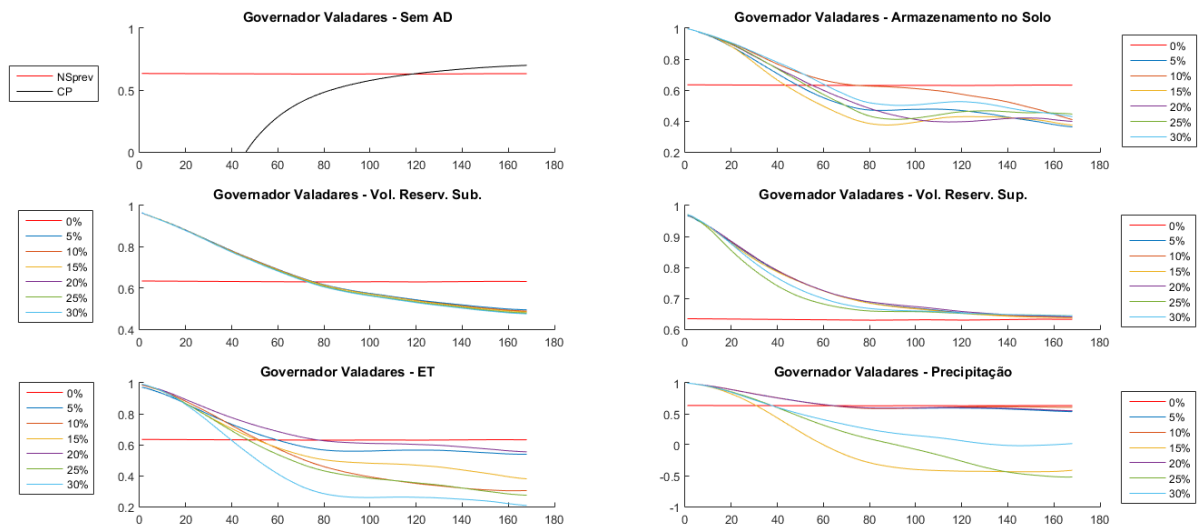


Figura 5 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Governador Valadares

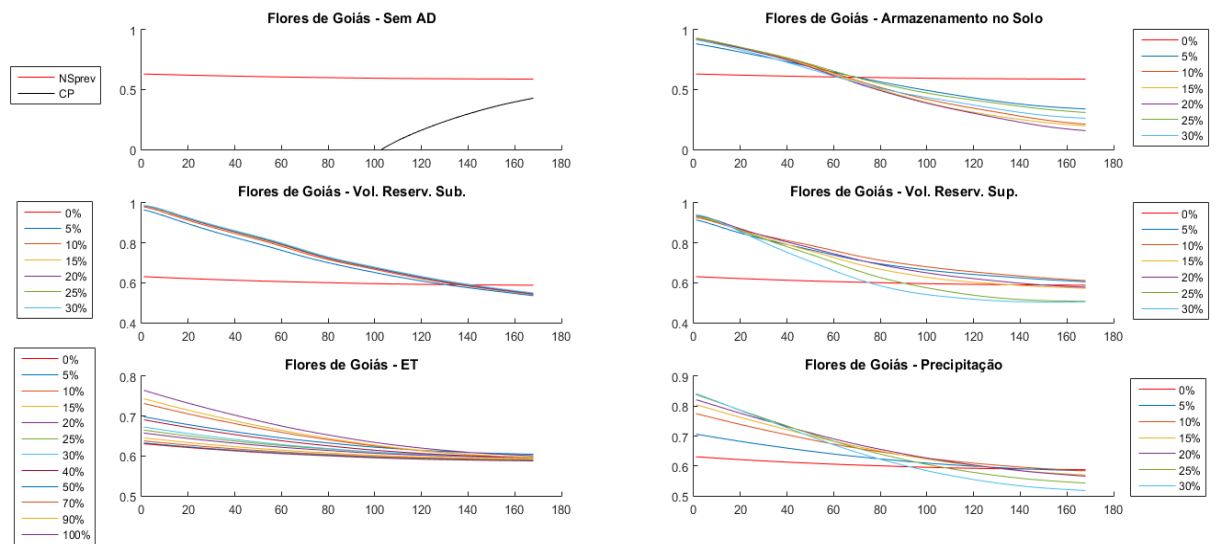


Figura 6 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Flores de Goiás

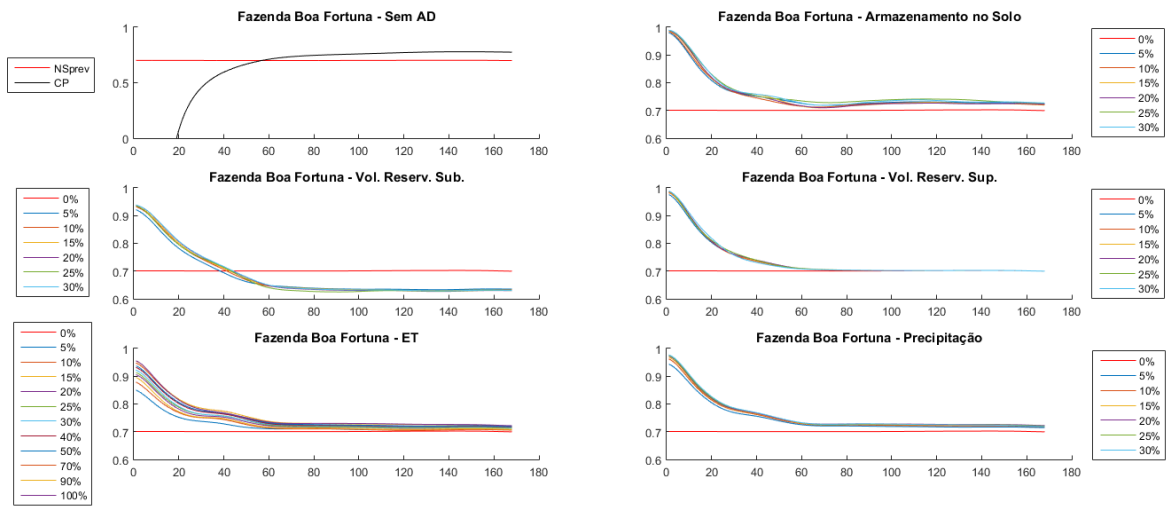


Figura 7 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Fazenda Boa Fortuna

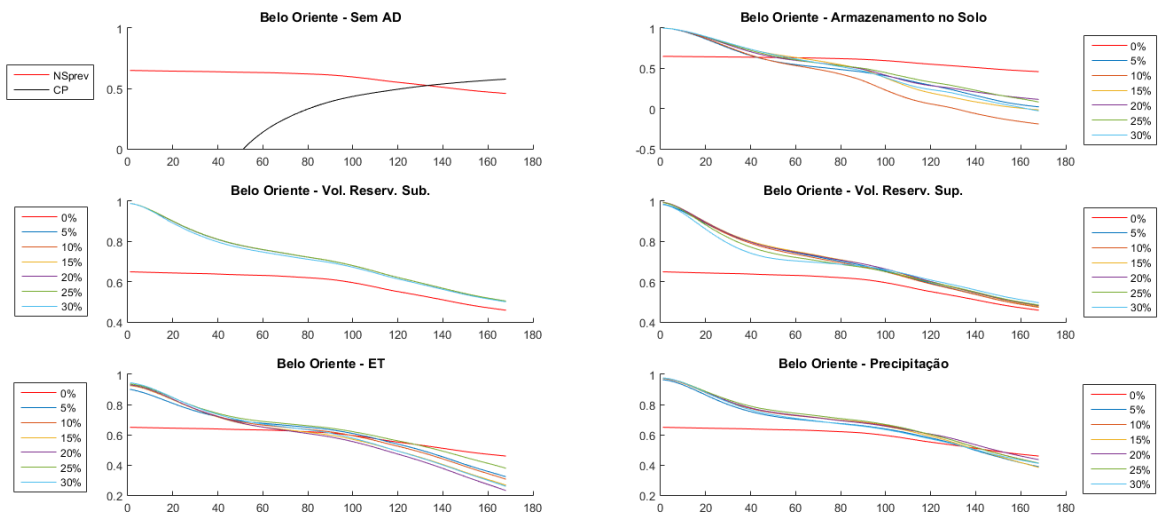


Figura 8 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Belo oriente

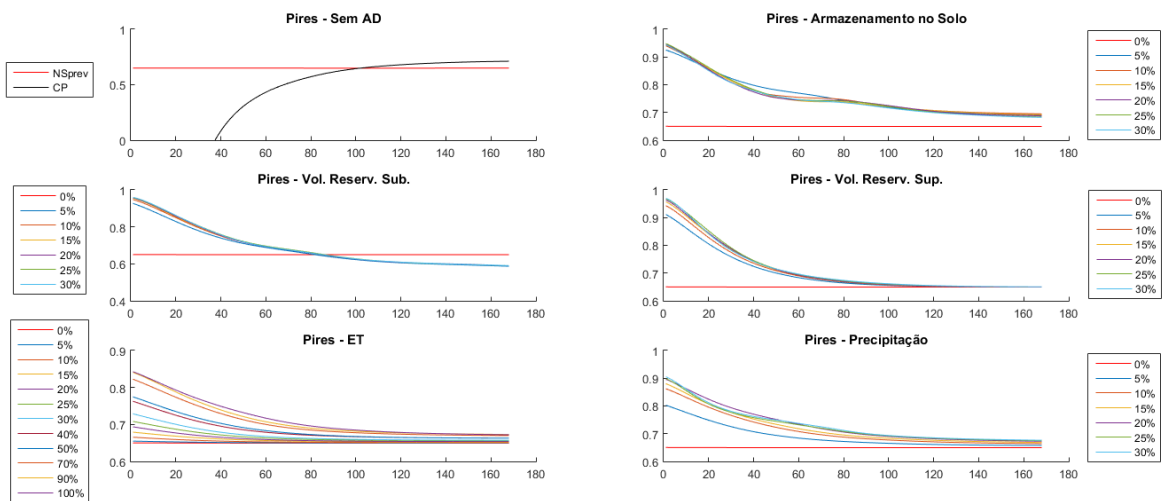


Figura 9 – Análise de sensibilidade das estimativas de erros das variáveis de estado em Pires

8.2. DEFINIÇÃO DO NÚMERO DE MEMBROS DO ENSEMBLE

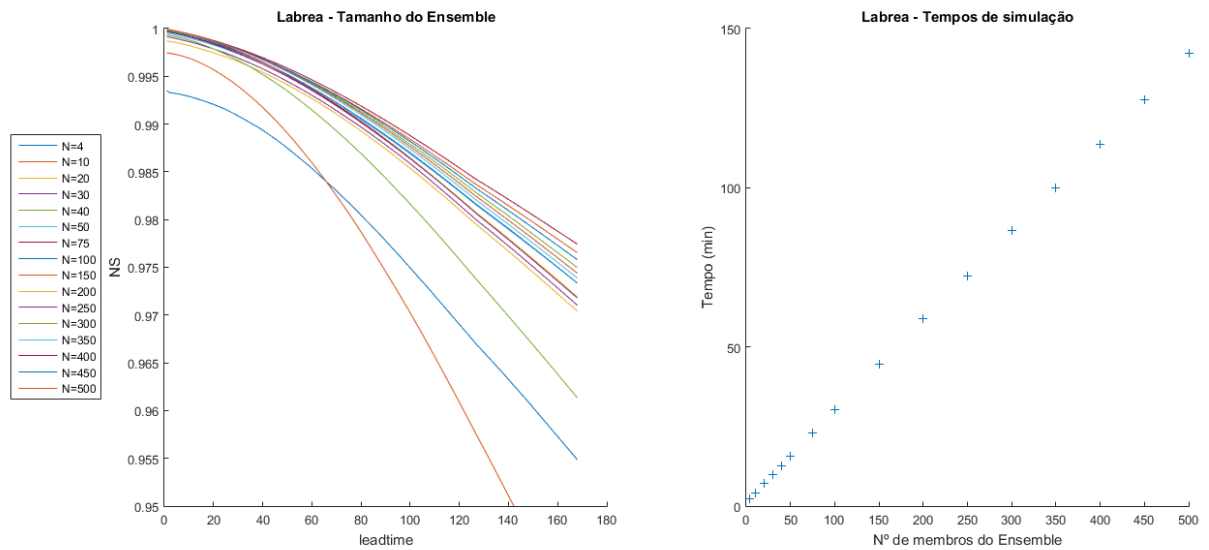


Figura 10 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Labrea.

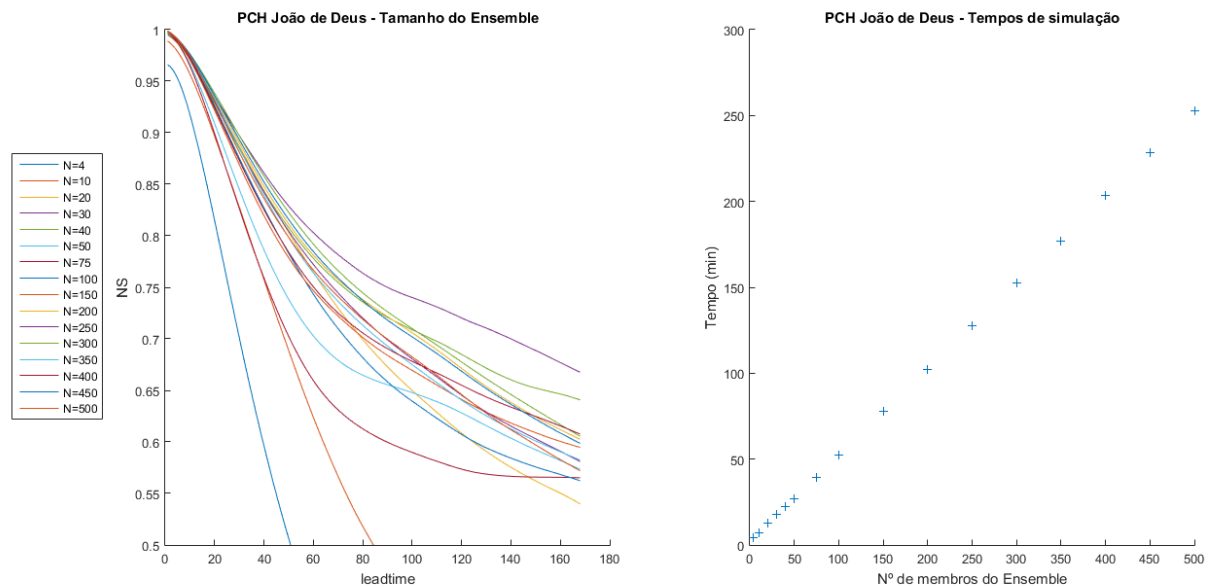


Figura 11 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto PCH João de Deus.

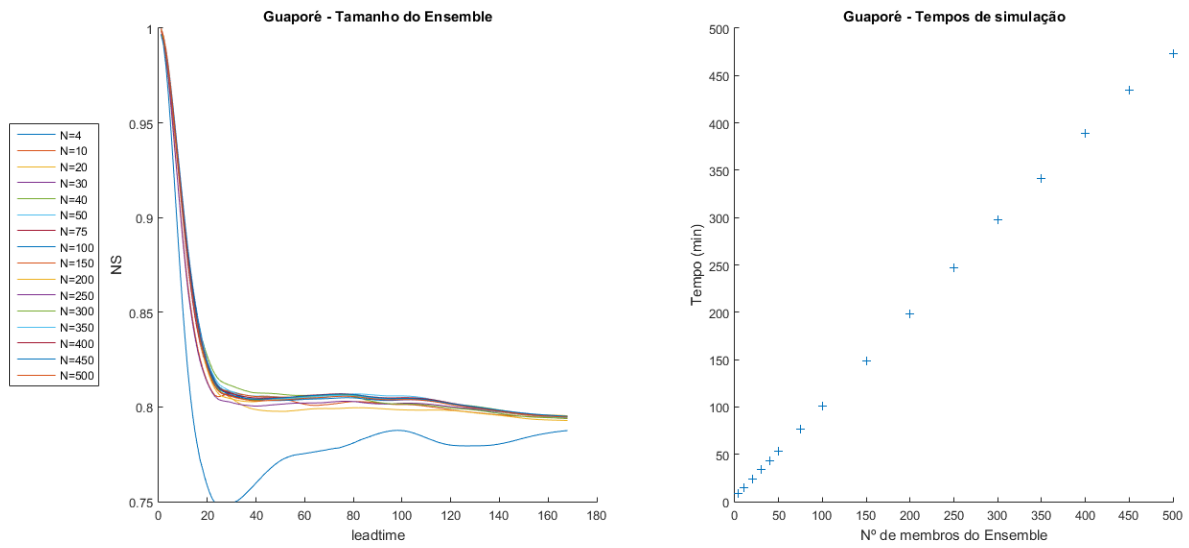


Figura 12 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Guaporé.

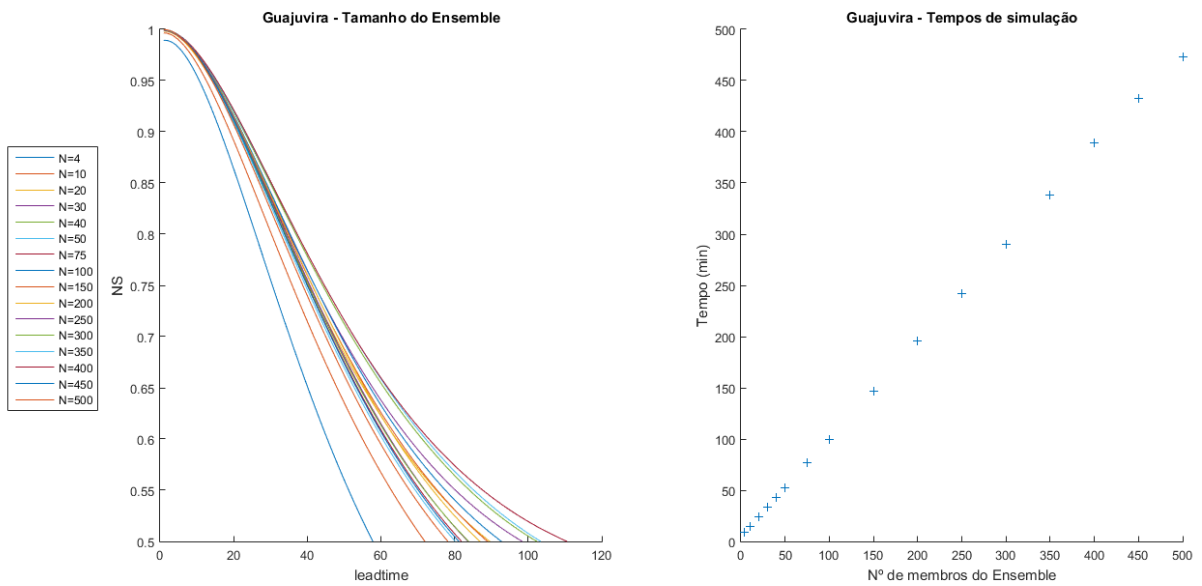


Figura 13 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Guajuvira.

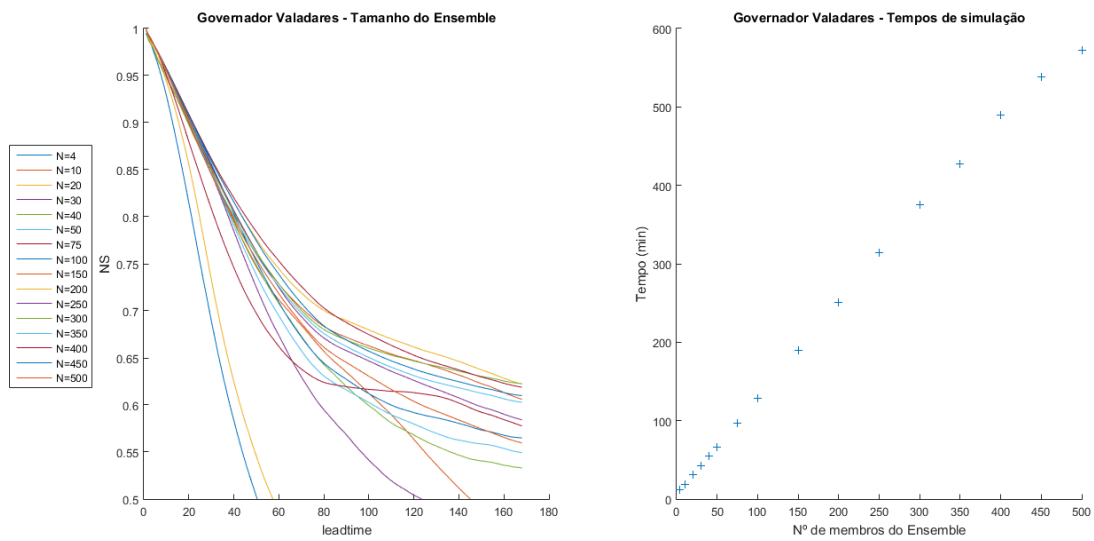


Figura 14 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Governador Valadares.

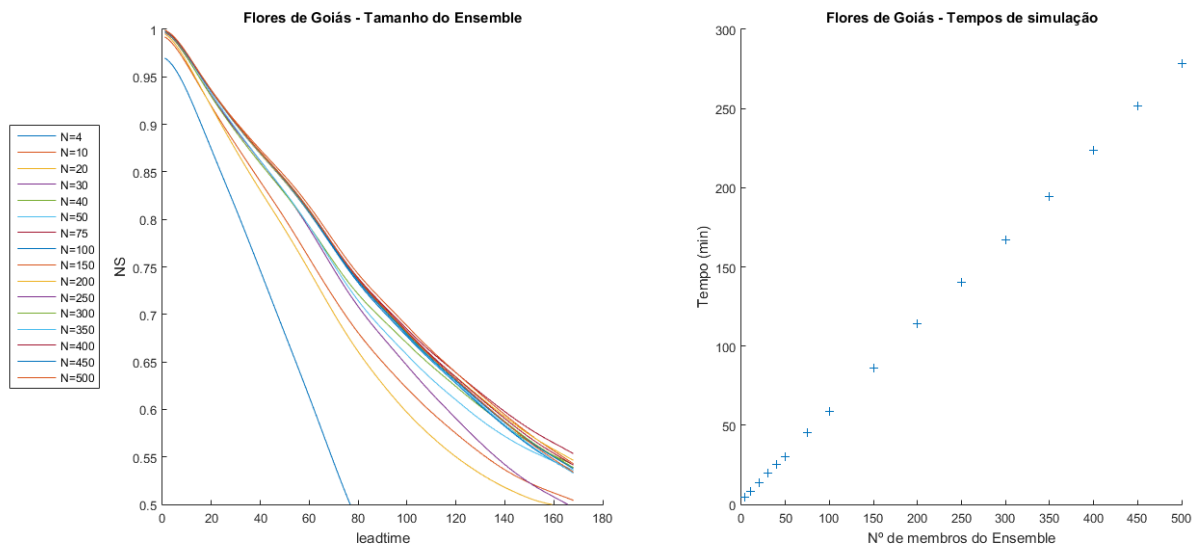


Figura 15 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Flores de Goiás.

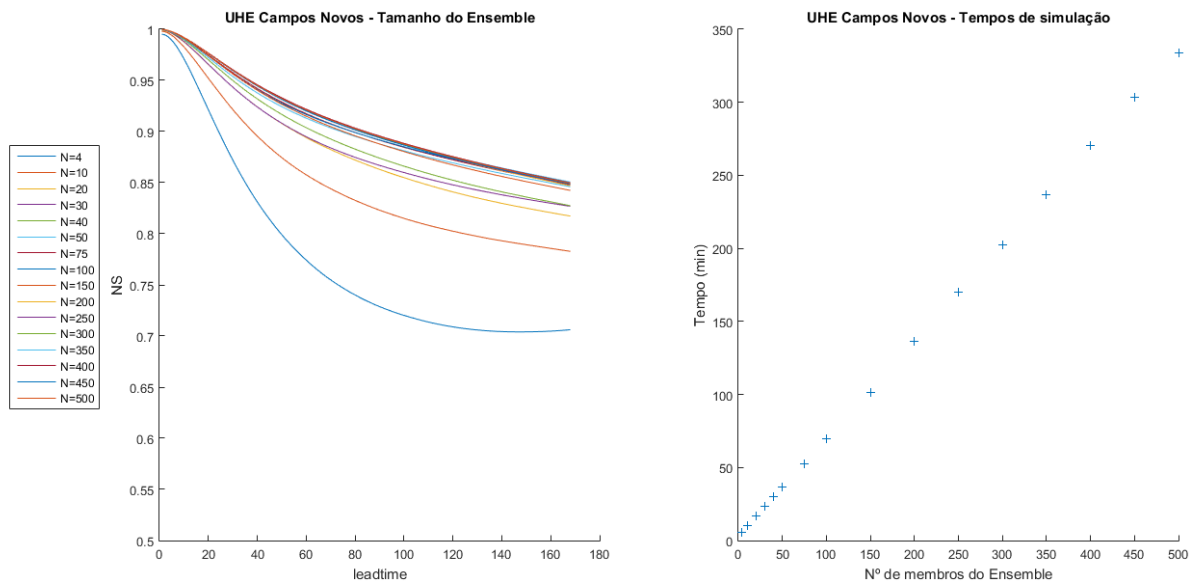


Figura 16 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto UHE Campos Novos.




Figura 17 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Belo Oriente.




Figura 18 – Desempenhos das previsões com horizonte de até 168, medidos em termos do coeficiente de Nash-Sutcliffe, e tempos de simulações em função do número de membros no Ensemble para a bacia do posto Pires.

8.3. HIDROGRAMAS DE PREVISÕES BASEADAS EM CHUVA REAL, GEFS E CHUVA REAL SEM AD, HORIZONTES DE 5 E 24 HORAS




Figura 19 – Hidrogramas de vazões previstas com antecedência de 24h para a bacia Pires. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

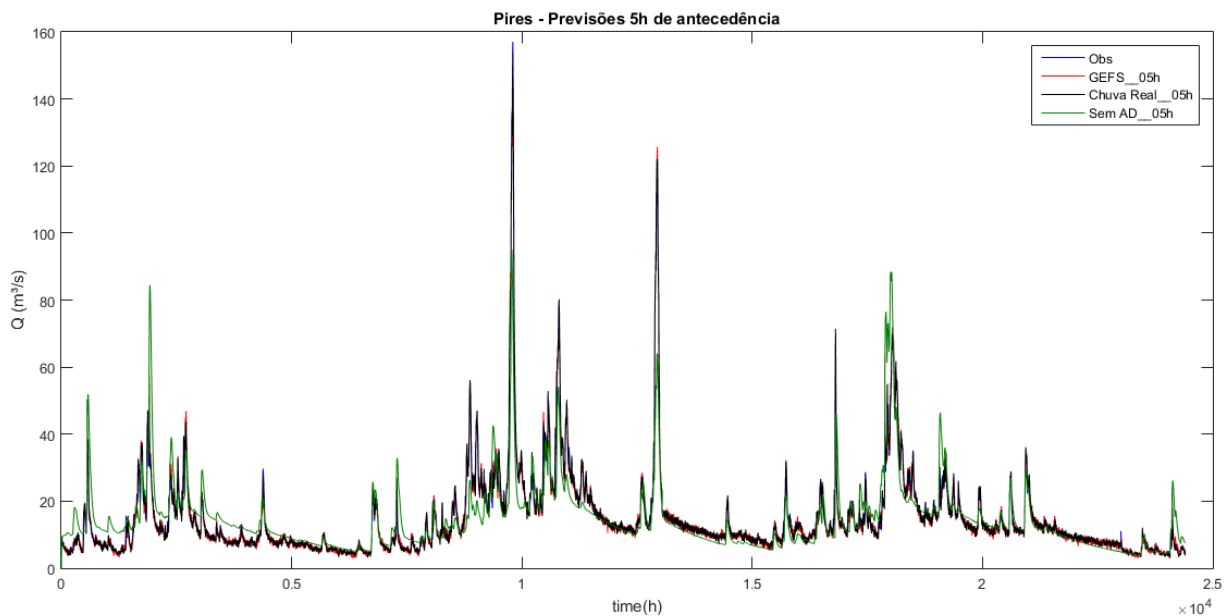


Figura 20 – Hidrogramas de vazões previstas com antecedência de 05h para a bacia Pires. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

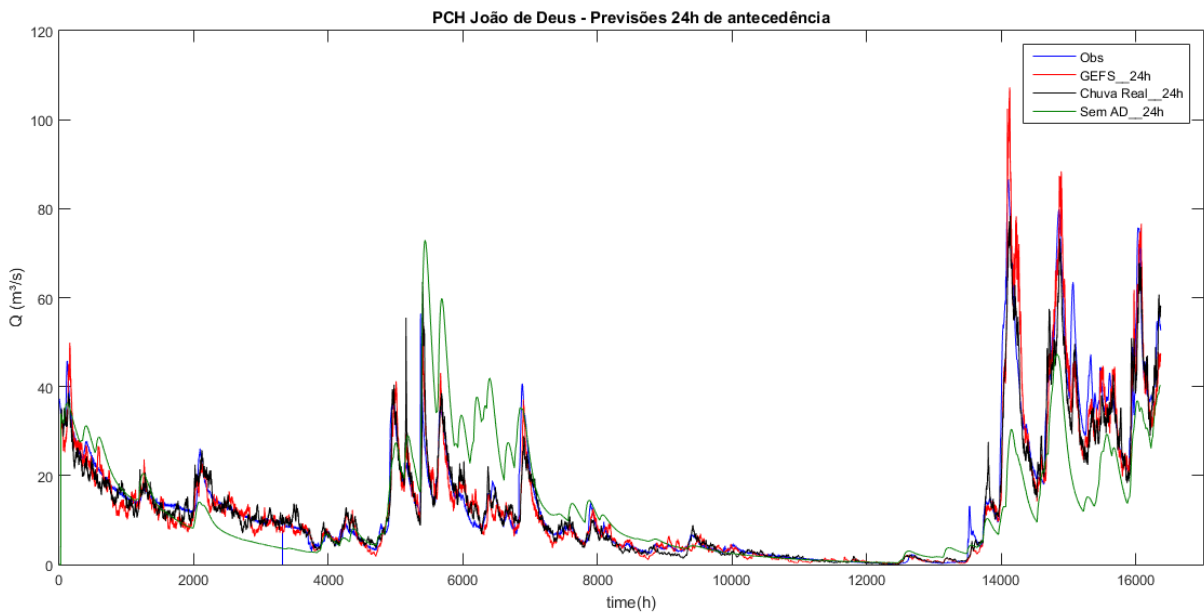


Figura 21 – Hidrogramas de vazões previstas com antecedência de 24h para a bacia PCH João de Deus. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

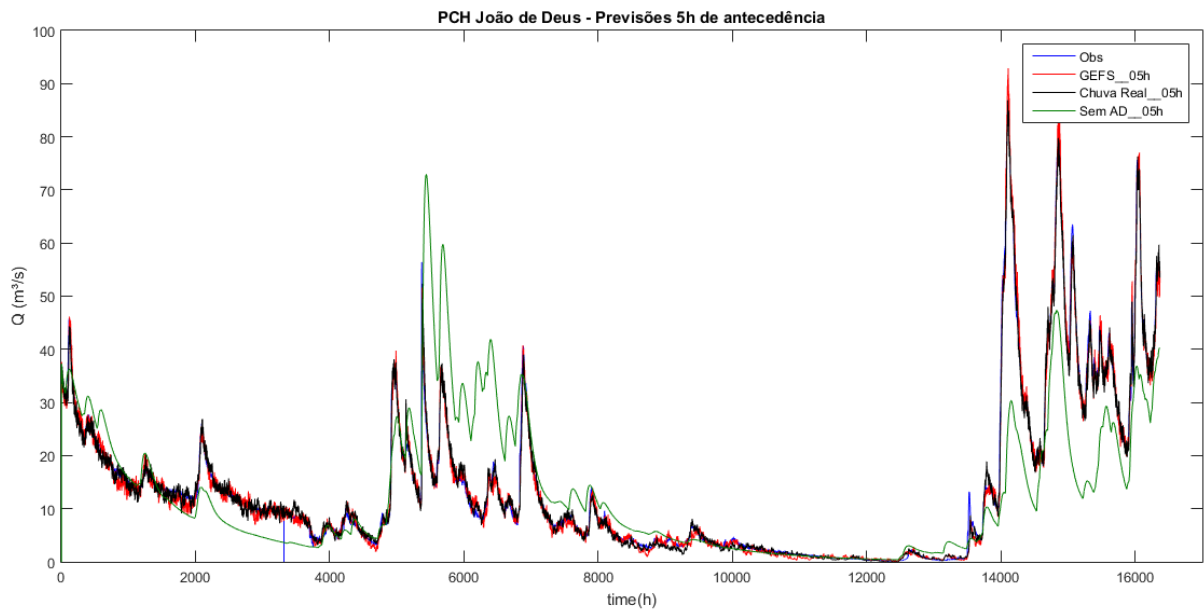


Figura 22 – Hidrogramas de vazões previstas com antecedência de 05h para a bacia PCH João de Deus. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.




Figura 23 – Hidrogramas de vazões previstas com antecedência de 24h para a bacia Flores de Goiás. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

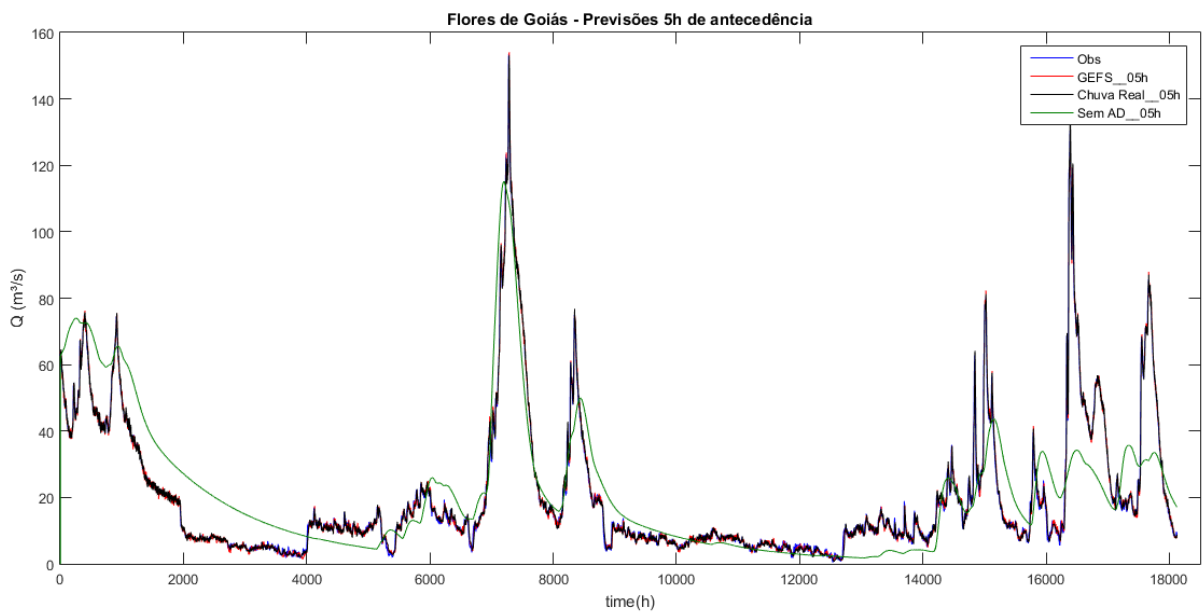


Figura 24 – Hidrogramas de vazões previstas com antecedência de 05h para a bacia Flores de Goiás. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.

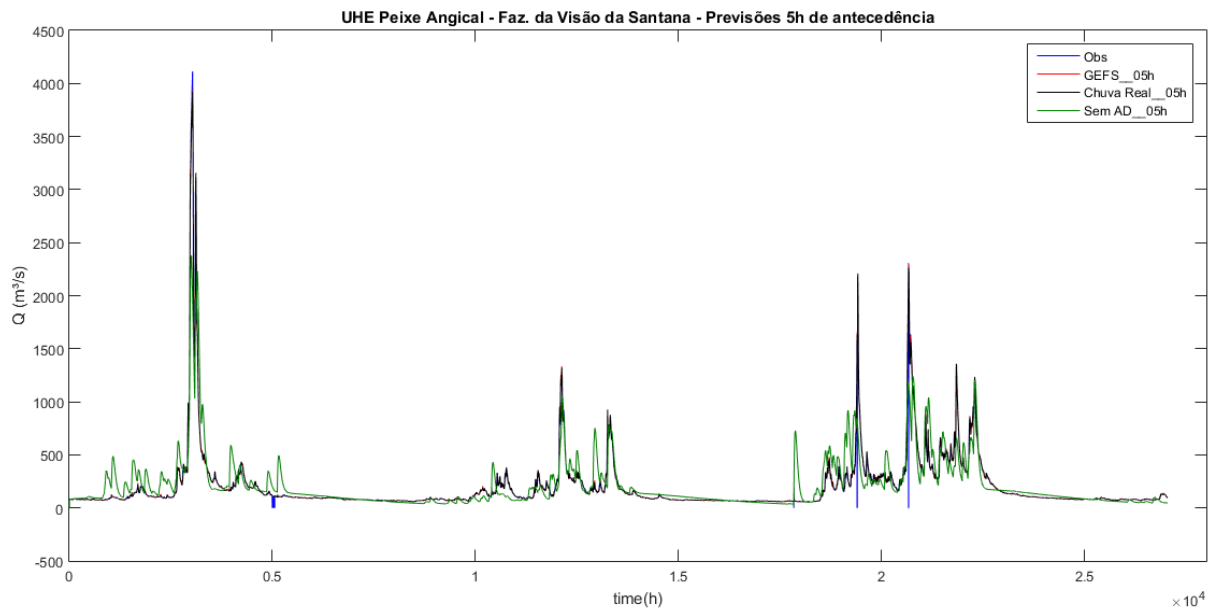


Figura 25 – Hidrogramas de vazões previstas com antecedência de 24h para a bacia UHE Peixe Angical. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.




Figura 26 – Hidrogramas de vazões previstas com antecedência de 05h para a bacia UHE Peixe Angical. Em vermelho, previsões com estimativas do modelo GEFS; em preto, previsões com chuva real; em verde, previsões chuva real sem assimilação de dados e em azul os dados observados.