## UNIVERSIDADE DE SÃO PAULO INSTITUTO DE ASTRONOMIA GEOFÍSICA E CIÊNCIAS ATMOSFÉRICAS

CALUAN RODRIGUES CAPOZZOLI

Modelagem hidrológica de inundação utilizando previsões de precipitação por conjuntos e pós-processadas

São Paulo 2024

## CALUAN RODRIGUES CAPOZZOLI

# Modelagem hidrológica de inundação utilizando previsões de precipitação por conjuntos e pós-processadas

Versão Original

Tese apresentada ao Departamento de Ciências Atmosféricas do Instituto de Astronomia Geofísica e Ciências Atmosféricas da Universidade de São Paulo como requisito para obtenção do título de Doutorado em Ciências.

Área de concentração: Meteorologia

Orientador: Prof. Dr. Edmilson Dias de Freitas

São Paulo 2024 Autorizo a reprodução total ou parcial deste trabalho por qualquer meio convencional ou eletrônico para fins de estudo e pesquisa, desde que citada a fonte.

## Catalogação na publicação Serviço de Biblioteca e Documentação

Instituto de Astronomia Geofísica e Ciências Atmosféricas da Universidade de São Paulo

Capozzoli, Caluan Rodrigues.

Modelagem hidrológica de inundação utilizando previsões de precipitação por conjuntos e pós-processadas / Caluan Rodrigues Capozzoli; orientador: Edmilson Dias de Freitas. – São Paulo, 2024. 237f.

Tese (Doutorado) - Programa de Pós-Graduação em Meteorologia) --Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo.

1. Previsão de inundação por conjuntos 2.pós-processamento estatístico 3.previsão de chuva por conjuntos I. Freitas, Edmilson Dias de, oriente. II. Título.



### Universidade de São Paulo

## ATA DE DEFESA

Aluno: 14133 - 10105638 - 2 / Página 1 de 1

Fanus

Ata de defesa de Tese do(a) Senhor(a) Caluan Rodrigues Capozzoli no Programa: Meteorologia, do(a) Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo.

Aos 09 dias do mês de outubro de 2024, no(a) IAG, realizou-se a Defesa da Tese do(a) Senhor(a) Caluan Rodrigues Capozzoli, apresentada para a obtenção do título de Doutor intitulada:

"Modelagem hidrológica de inundação utilizando previsões de precipitação por conjuntos e pós-processadas"

Após declarada aberta a sessão, o(a) Sr(a) Presidente passa a palavra ao candidato para exposição e a seguir aos examinadores para as devidas arguições que se desenvolvem nos termos regimentais. Em seguida, a Comissão Julgadora proclama o resultado:

Nome dos Participantes da Banca	Função	Sigla da CPG	Resultado
Edmilson Dias de Freitas	Presidente	IAG - USP	Agrievado
Ricardo Hallak	Titular	IAG - USP	Aprovado
Andréa de Oliveira Cardoso	Titular	UFABC - Externo,	Andrew de alain adiso
Benedito Claudio da Silva	Titular	UNIFEI - Externo	Agroundo
Joaquin Ignacio Bonnecarrere Garcia	Titular	EP - USP	Aprovado

PROVAC **Resultado Final:** 

Parecer da Comissão Julgadora \*

Eu, Marcel Yoshio Kimura \_\_\_\_\_\_, lavrei a presente ata, que assino juntamente com os(as) Senhores(as). São Paulo, aos 09 dias do mês de outubro de 2024.

Ricardo Hallak Benedito Claudio da Si

(PORNIVED COUFERED

Ignacio Bonnecarrere Garcia

Edmilson Dias de Preitas Presidente da Comissão Julgadora

\* Obs: Se o candidato for reprovado por algum dos membros, o preenchimento do parecer é obrigatório.

A defesa foi homologada pela Comissão de Pós-Graduação em \_\_\_\_\_\_e, portanto, o(a) aluno(a) \_\_\_\_\_\_jus ao título de Doutor em Clências obtido no Programa Meteorologia.

Presidente da Comissão de Pós-Graduação

Prof. Dr. Marcos Peraz Diaz Presidente da CPG – IAG Aos meus irmãos Cauai e Arethuza.

## AGRADECIMENTOS

A Thaís Fujita pela amizade, apoio e ajuda em todas as etapas de desenvolvimento deste trabalho. Sua amizade foi um presente nesta jornada.

Ao professor Dr. Edmilson Dias de Freitas pela orientação deste trabalho.

Ao Serviço Geológico do Brasil pelo apoio institucional.

"Quem tem só o pescoço põe a prova"

(Don L, Bingo)

#### RESUMO

CAPOZZOLI, C. R. **Modelagem hidrológica de inundação utilizando previsões de precipitação por conjuntos e pós-processadas.** 2024, 234 f. Tese (Doutorado) – Instituto de Astronomia Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2024.

Uma importante medida de mitigação dos impactos sociais e econômicos de inundações são os sistemas de alerta hidrológico, sendo os sistemas de previsão de cotas ou vazões (previsões hidrológicas) baseadas em conjuntos de previsões numéricas de precipitação, uma alternativa promissora que aumenta a antecedência e melhora a fundamentação para tomada de decisão. Contudo, o uso das previsões numéricas de precipitação para previsões hidrológicas pode implicar em previsões de vazão enviesadas, sendo indicado corrigir as previsões numéricas de precipitação. O objetivo deste trabalho foi testar se a aplicação de técnicas de processamento das previsões numéricas de precipitação pode melhorar o desempenho das previsões hidrológicas de vazão nas bacias hidrográficas do rio Paraíba do Sul (BHPS) e do rio Caí (BHRC) localizadas nas regiões sudeste e sul do Brasil, respectivamente. O modelo hidrológico Soil and Water Assessment Tools (SWAT), previamente calibrado e validado para cada uma das bacias hidrográficas, foi alimentado com o conjunto de previsões numéricas de precipitação do European Centre for Medium-Range Weather Forecasts (ECMWF) e com os quantis de precipitação das previsões processadas. Foram testadas as técnicas de processamento Ensemble Model Output Statistics (utilizando as funções de probabilidade Generalizada de Valores Extremos - GEV - e Gama limitada - CSG) e Bayesian Model Average (BMA). Os resultados mostram que o uso dos quantis de probabilidade oriundos do processamento das previsões numéricas de precipitação por conjunto melhorou a qualidade das previsões hidrológicas em todos os horizontes de previsão testados (24 h, 48 h, 72 h, 96 h e 120 h), quando comparados com as previsões hidrológicas geradas com as previsões numéricas do ECMWF. O processamento permitiu reduzir o viés das previsões de precipitação e melhorar o espalhamento dos membros do conjunto. O processamento melhora a previsão de precipitação e este benefício se propaga para as previsões hidrológicas, quando as previsões processadas são utilizadas. Em ambas as bacias foi observado que o processamento com a BMA promove alguma melhora no viés, mas não no espalhamento dos membros do conjunto, enquanto que o processamento com a GEV e com CSG melhoram o viés e o espalhamento dos membros. Entre os modelos GEV e CSG, o segundo é o que apresentou o melhor desempenho.

Palavras-chave: Previsão de inundação por conjuntos, pós-processamento estatístico, previsão de chuva por conjuntos.

#### ABSTRACT

CAPOZZOLI, C. R. Hydrological modeling of flood using ensemble and post-processed precipitation forecasts. 2024, 234 p. Tese (Doutorado) – Instituto de Astronomia Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2024.

An important measure to mitigate the social and economic impacts of floods is the implementation of hydrological warning systems. Among the possible configurations of these systems, recent literature highlights stage or flow forecasting systems (hydrological forecasts) based on ensemble numerical rainfall forecasts as a promising alternative that increases the leading time and improves the basis for decision-making. However, the use of numerical precipitation forecasts for hydrological predictions can result in biased hydrological forecasts, indicating the need to apply processing techniques to overcome the limitations of numerical precipitation forecasts. In this work, it was evaluated whether the application of processing techniques to numerical precipitation forecasts can improve the performance of streamflow hydrological forecasts in the Paraíba do Sul (PSRB) and the Caí river basin (CRB), located in the southeastern and southern regions of Brazil, respectively. The processing techniques tested were Ensemble Model Output Statistics (using Generalized Extreme Value - GEV - and Censored-Shifted Gamma - CSG - probability functions) and Bayesian Model Average (BMA). The results show that the use of probability quantiles derived from the processing of ensemble numerical precipitation forecasts improved the quality of hydrological forecasts across all tested forecast horizons (24 h, 48 h, 72 h, 96 h, and 120 h). Processing reduced forecast bias and improved the spread of ensemble members. Improved precipitation forecasts through processing also benefitted hydrological forecasts when processed forecasts were used in hydrological forecasts. In both basins, BMA processing showed some improvement in bias but not in the spread of ensemble members, while GEV and CSG processing improved both bias and spread. Among the GEV and CSG models, the latter demonstrated the best performance.

Keywords: Ensemble flood forecast, Statistical post-processing, Rainfall ensemble forecasting

## LISTA DE FIGURAS

Figura 1 – Fluxograma com os passos gerais da metodologia desenvolvida neste trabalho 38
Figura 2 – Exemplo de resultado do CRPS para definição da janela de treinamento, neste caso os
autores definiram a janela em 87 dias 53
Figura 3 - Esquema de alimentação do modelo hidrológico utilizando previsões quantitativas de
precipitação do ECMWF
Figura 4 - Esquema de alimentação do modelo hidrológico utilizando os quantis de probabilidade
gerados com as previsões de precipitação processada
Figura 5 – Hidrograma observado e simulado, na figura (a) a vazão simulada é subestimada pelo
modelo enquanto que em (b) as vazões simuladas são superestimadas
Figura 6 - Esquema de curva ROC indicando seus componentes
Figura 7 - Exemplos de curvas de distribuição com suas respectivas avaliações de acordo com a
forma da curva. A linha tracejada indica o limiar de uniformidade que é dado pela reta 1:1, no
eixo X são indicadas as probabilidades de previsões e no eixo Y é indicada a frequência
condicional de observação de um evento dada a sua probabilidade de previsão
Figura 8 - Exemplos de gráficos de refinamento da distribuição com baixa, média e alta confiança
Figura 9 - Exemplos de <i>rank histograms</i> com suas respectivas avaliações de acordo com a forma
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) $-1$ .
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) $- 1$ , no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro)
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 64
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 
do histograma. A linha tracejada indica o limiar de uniformidade que é dado por ( <i>Nclasses</i> ) – 1, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma determinada posição 

ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de Figura 18 – Brier Score para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja) utilizando os limiares de 0,1 Figura 19 - Rank Histogram para previsões de precipitação da BHPS para horizontes de previsão de 24 h a 120 h. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura 20 - Probability Integral Transform histogram (PIT) dos modelos BMA (azul), GEV (verde) e CSG (laranja) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna). A linha horizontal tracejada indica o comportamento desejado do gráfico de barras, no Figura 21 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 0,1 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 22 – Diagrama de Confiabilidade (Reliability Diagram) para chuvas acima de 5 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 23 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 10 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 24 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 15 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 25 – Curva ROC para chuvas acima de 0,1 mm, 5 mm, 10 mm e 15 mm, para previsões com horizontes de 24 h a 120 h. A curva apresenta no eixo X a probabilidade de alarme falso e no eixo Y a probabilidade de detecção do evento, sendo representado conjuntamente a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A reta identidade indica a climatologia e a curva ideal deve ficar acima e o mais distante possível da Figura 26 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste para os postos de monitoramento fluviométrico da bacia do rio Paraíba do Sul (linhas) para horizontes de

previsão de 24 h a 120 h (colunas). O gradiente de cores indica o percentil das amostras Figura 27 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste do posto de monitoramento fluviométrico Santa Cecília para horizontes de previsão de 24 h a 120 h (linhas) separados de acordo com trimestres (colunas) DJF (dezembro- janeiro - fevereiro), MAM (março - abril - maio), JJA (junho- julho- agosto) e SON (setembro - outubro - novembro). O gradiente Figura 28 – Coeficiente de correlação (R<sup>2</sup>), Erro Médio Absoluto (EMA) e Erro Médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda Figura 29 – Brier Score (BS) considerando como limiar de cheia o percentil 75% da vazão e Continous Ranked Probability Score (CRPS), entre vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste, para o posto Santa Cecília.... 98 Figura 30 - Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às Figura 31 - Diagrama de Confiabilidade (Reliability Diagram) da estação Santa Cecília utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado ...... 100 Figura 32 – Rank Histogram para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura 33 – PIT histogram para previsões de precipitação processadas da BRPS em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros Figura 34 – Hidrogramas de previsão da vazão máxima diária do período de estudo para o posto Santa Cecília. A linha tracejada horizontal indica o dia do evento e a linha tracejada em vermelho a vazão observada......Erro! Indicador não definido. Figura 35 – Localização bacia hidrográfica do Rio Caí (BHRC)......111 Figura 36 – Cobertura da superfície da Bacia Hidrográfica do Rio Paraíba do Sul (BHRC) ..... 112 Figura 37 – Modelo Digital de Elevação da Bacia Hidrográfica do Caí, postos fluviométricos utilizados e gráficos chuva-vazão ilustrativo do comportamento hidrológico da bacia...... 113

Figura 38- Divisão em minibacias e representação da (a) drenagem gerada pelo SWAT, (b) centroides das minibacias, (c) centroides da grade de reanálise e (d) centroides da grade de chuva Figura 39- Classificação de cobertura (a), solos (b) e declividade (c) utilizada para cruzamento e Figura 41 – Continous Rank Probability (CRPS) em função do tamanho da janela de treinamento (em dias) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna) e para os diferentes modelos probabilísticos (um modelo em cada linha, com cores diferentes) ...... 126 Figura 42 – Coeficientes determinísticos para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja). Para o ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de Figura 43 – Brier Score para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja) utilizando os limiares de 0,1 mm, 5 mm, 10 mm e 15 mm para discriminação de eventos. ..... 128 Figura 44 - Rank Histogram para previsões de precipitação da BHPS para horizontes de previsão de 24 h a 120 h. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura 45 - Probability Integral Transform histogram (PIT) dos modelos BMA (azul), GEV (verde) e CSG (laranja) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna). A linha horizontal tracejada indica o comportamento desejado do gráfico de barras, no Figura 46 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 0,1 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 47 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 5 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 48 - Diagrama de Confiabilidade (Reliability Diagram) para chuvas acima de 10 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 49 – Diagrama de Confiabilidade (Reliability Diagram) para chuvas acima de 15 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto),

processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da Figura 50 – Curva ROC para chuvas acima de 0,1 mm, 5 mm, 10 mm e 15 mm, para previsões com horizontes de 24 h a 120 h. A curva apresenta no eixo X a probabilidade de alarme falso e no eixo Y a probabilidade de detecção do evento, sendo representado conjuntamente a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A reta identidade indica a climatologia e a curva ideal deve ficar acima e o mais distante possível da Figura 51 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste para os postos de monitoramento fluviométrico da bacia do rio Caí (linhas) para horizontes de previsão de 24 h a 120 h (colunas). O gradiente de cores indica o percentil das amostras associadas ao erro Figura 52 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste do posto de monitoramento fluviométrico Passo Montenegro para horizontes de previsão de 24 h a 120 h (linhas) separados de acordo com trimestres (colunas) DJF (dezembro- janeiro – fevereiro), MAM (março - abril - maio), JJA (junho- julho- agosto) e SON (setembro - outubro novembro). O gradiente de cores indica o percentil das amostras associadas ao erro encontrado Figura 53 - Coeficiente de correlação (R), Erro Médio Absoluto (EMA) e Erro Médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as Figura 54 - Brier Score (BS) considerando como limiar de cheia o percentil 75% da vazão e Continous Ranked Probability Score (CRPS), entre vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste, para o posto Passo Figura 55 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às Figura 56 – Diagrama de Confiabilidade (Reliability Diagram) da estação Ponte Alta I utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento 

Figura 57 – Rank Histogram para previsões de vazão da BHRC para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura 58 – PIT histogram para previsões de precipitação processadas da BHRC em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros Figura 59 – Hidrogramas de previsão da vazão máxima diária do período de estudo para o posto Passo Montenegro. A linha tracejada horizontal indica o dia do evento e a linha tracejada em Figura C1- Coeficiente de Nash da melhor simulação, de acordo com a média do coeficiente de Figura C2 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos Figura C3 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos fluviométricos da bacia do rio Paraíba do Sul no período de validação...... 174 Figura C4 – Coeficiente de correlação (R) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste e os postos estão Figura C5 – Erro médio absoluto (EMA) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as Figura C6 - Erro médio relativo (EMR) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as Figura C7 – Brier Score (BS) considerando como limiar de cheia o percentil 75% da vazão, e vazão observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem Figura C8 - Continuous Ranked Probability Score (CRPS) entre a vazão prevista e a observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e

Figura C9 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às Figura C10 – Diagrama de Confiabilidade (Reliability Diagram) da estação Ponte Alta I utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração Figura C12 – Mesmo que na Figura C10, mas para a estação São Luís do Paraitinga ...... 188 Figura C15 – Rank Histogram para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura C16 – PIT histograms para previsões de precipitação processadas da BRPS em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros Figura C17 – Hidrogramas de previsão da máxima de vazão do período de estudo para o posto Ponte Alta I. A linha tracejada horizontal indica o dia do evento e a linha tracejada em vermelho Figura C18 – Mesmo que na Figura C17, mas para a estação Estrada do Cunha. ..... 196 Figura D1 – Coeficiente de Nash da melhor simulação, de acordo com o valor médio, em cada uma das cinco rodadas de 500 simulações realizadas 202 Figura D2 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos Figura D3 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos Figura D4 – Coeficiente de correlação (R) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste. Os postos estão Figura D5 – Erro médio absoluto (EMA) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja)

calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as Figura D6 – Erro médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com Figura D7 - Brier Score (BS) considerando como limiar de cheia o percentil 75% da vazão e vazão observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem Figura D8 – Continuous Ranked Probability Score (CRPS) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste...... 218 Figura D9 - Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às Figura D10 – Diagrama de Confiabilidade (Reliability Diagram) da estação Estrada do Cunha utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração Figura D11 – Mesmo que na figura D10, mas para a estação São Luís do Paraitinga...... 221 Figura D12 – Mesmo que na figura D10, mas para aestação Ponte Alta I..... 222 Figura D15 – Rank Histogram para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam Figura D16 – PIT *histogram* para previsões de precipitação processadas da BHAT em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros 

## LISTA DE TABELAS

Tabela 1 – Características dos principais sistemas de previsão numérica
Tabela 2 – Exemplo de valores de CN2 (valor da curva número do SCS para condição de
umidade II) para solos de diferentes grupos hidrológicos (A, B, C e D) extraído do banco de
dados disponível no SWAT
Tabela 3 – Parâmetros utilizados para análise de sensibilidade e seus respectivos valores iniciais.
Para o tipo de mudança "Valor", o valor inicial é substituído por valores dentro do intervalo
especificado e para mudança relativa o valor inicial é multiplicado por 1+ r, em que r é um valor
no intervalo especificado
Tabela 4 – Características dos principais reservatórios existentes na bacia, onde AD se refere à
área de drenagem a montante do reservatório e AI à área inundada pelo reservatório
Tabela 5 – Estatísticas descritivas do regime de vazão dos postos de monitoramento: vazão média
(Q), desvio padrão (SD), coeficiente de variação, vazão com permanência de superação de 10%,
e 95% (Q10% e Q95%, respectivamente), razão entre Q10% e Q50%, vazão máxima diária anual
média (MDM), assimetria (S) e curtose (K)
Tabela 6 – Reclassificação das classes de cobertura da superfície do Mapbiomas para as classes
do banco de dados do SWAT
Tabela 7 – Valores iniciais dos parâmetros de superfície relevantes para geração de escoamento
Tabela 8 – Valores iniciais dos parâmetros de solo para geração de escoamento
Tabela 9 – Resultado da análise de sensibilidade dos parâmetros importantes para representação
da vazão na bacia do rio Paraíba do Sul. Em negrito estão destacados os parâmetros cuja
sensibilidade é estatisticamente significativa (p-valor < 5%)
Tabela 10 – Parâmetros utilizados para iniciar e calibração do modelo. Para o tipo de mudança
Valor, o valor inicial é substituído por valores dentro do intervalo especificado e para mudança
relativa o valor inicial é multiplicado por 1+ r, em que r é um valor no intervalo especificado 77
Tabela 11 - Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE) e Erro Médio Absoluto (EMA) para o período de calibração
(01/01/2005 até 31/12/2011)
Tabela 12 - Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R2), Raiz do Erro
Quadrático Médio (RMSE), Erro Médio Absoluto (EMA) e Erro Médio (EM) para o período de
validação
Tabela 13 – Data e valor da vazão máxima registrada no período de estudo em cada posto de
monitoramento
Tabela 14 - Estatísticas descritivas do regime de vazão dos postos de monitoramento: vazão
média (Q), desvio padrão (SD), coeficiente de variação, vazão com permanência de superação de
10%, e 95% (Q10% e Q95%, respectivamente), razão entre Q10% e Q50%, assimetria (S),
curtose (K) e vazão máxima diária anual média (MDM)114
Tabela 15 – Reclassificação das classes de cobertura da superfície do Mapbiomas para as classes
do banco de dados do SWAT 117
Tabela 16 – Valores iniciais dos parâmetros de superfície relevantes para geração de escoamento
Tabela 17 – Valores iniciais dos parâmetros de solo para geração de escoamento 118
Tabela 18 – Resultado da análise de sensibilidade dos parâmetros importantes para representação
da vazão na bacia do rio Caí

Tabela 19 – Parâmetros utilizados para calibração. Para o tipo de mudança Valor, o valor inicial é
substituído por valores dentro do intervalo especificado e para mudança relativa o valor inicial é
multiplicado por 1+ r, em que r é um valor no intervalo especificado
Tabela 20 - Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE), Erro Absoluto (EMA) e Erro Médio (EM) para o período de
calibração (15/09/2015 a 31/12/2016)
Tabela 21 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE), Erro Absoluto (absBIAS) e Erro médio (EM) para o período de
validação (01/01/2017 a 31/12/2019)
Tabela 22 – Data e valor da vazão máxima registrada no período de estudo em cada posto de
monitoramento
Tabela 23– Parâmetros de solo utilizados na base de dados do SWAT 166
Tabela A1 – Parâmetros de solo utilizados na base de dados do SWAT 167
Tabela A2 – Parâmetros de superfície utilizados no SWAT 167
Tabela B1 – Variação dos parâmetros de calibração em cada uma das rodadas de calibração para
a bacia do Rio Paraíba do Sul
Tabela B2 – Variação dos parâmetros de calibração em cada uma das rodadas de calibração para
a bacia do rio Caí 169
Tabela C1 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE), Erro Médio Absoluto (EMA) e Erro Médio (EM) para o período de
validação 173
Tabela C2 – Data e valor da vazão máxima registrada no período de estudo em cada posto de
monitoramento
Tabela DI – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE) e Erro Absoluto (absBIAS) para o período de calibração
Tabela D2 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro
Quadrático Médio (RMSE) e Erro Absoluto (absBIAS) para o período de validação 205
Tabela D3 – Data e valor da vazão máxima registrada no período de estudo em cada posto de
monitoramento

## SUMÁRIO

1	IN	TRO	DUÇÃO	23
2	RE	VIS	ÃO BIBLIOGRÁFICA	25
	2.1	Pre	evisão meteorológica de precipitação por conjunto	25
	2.2	Pro	ocessamento das previsões numéricas de precipitação	27
	2.3	Mo	odelagem hidrológica	31
	2.4	Pre	visão hidrológica por conjunto	33
3	M	etoi	DOLOGIA	38
	3.1	Mo	odelagem Hidrológica	39
	3.1	.1	Dados utilizados	40
	3.1	.2	Pré-processamento	40
	3.1	.3	Análise de sensibilidade	45
	3.1	.4	Calibração e verificação do modelo	47
	3.1	.5	Métricas de avaliação da calibração e validação do modelo hidrológico	48
	3.2	Pro	ocessamento das previsões numéricas de precipitação	50
	3.3	Ex	perimentos de previsão de vazão	54
	3.3	.1	Ajuste da vazão prevista	57
	3.4	Mé	étricas de avaliação das previsões de precipitação e de vazão	59
4 SU	PR JL	EVI	SÕES HIDROLÓGICAS PARA BACIA HIDROGRÁFICA DO RIO PARAÍBA	DO 65
	4.1	Ca	racterísticas da BHPS	65
	4.2	Pré	é-processamento do modelo hidrológico	71
	4.3 Rio F	An Paraít	álise de sensibilidade, calibração e validação do modelo hidrológico para Bacia d oa do Sul	75
	4.4	Pre	evisões numéricas de precipitação	79
	4.4	.1	Processamento das previsões numéricas de precipitação da BHPS	79
	4.5	Pre	evisões de vazão na Bacia Hidrográfica do Rio Paraíba do Sul	90
	4.5	.1	Comparação entre a previsão ajustada e sem ajuste	90
	4.5	.2	Comparação entre as previsões de vazão bruta e probabilísticas	94
	4.5	.3	Hidrogramas de previsão da máxima registrada	. 103
	4.6	Re	sumo e conclusões do capítulo	. 106

5	PRI	EVISÕES HIDROLÓGICAS PARA BACIA HIDROGRÁFICA DO RIO CAÍ	110
	5.1	Características da BHRC	110
	5.2	Pré-processamento do modelo hidrológico	115
	5.3	Análise de sensibilidade, calibração e validação do modelo hidrológico para Bacia	a do
	Rio C	aí	121
	5.4	Previsões numéricas de precipitação	124
	5.4.	1 Processamento das previsões numéricas de precipitação da BHRC	124
	5.5	Previsões de vazão na BHRC	134
	5.5.	1 Comparação entre a previsão ajustada e sem ajuste	134
	5.5.	2 Comparação entre as previsões de vazão bruta e probabilísticas	138
	5.5.	3 Hidrogramas de previsão da vazão máxima registrada	146
	5.6	Resumo e conclusões do capítulo	149
С	ONCL	USÕES	152
R	EFER	ÊNCIAS	157
A	PÊND	PICE A – Parâmetros utilizados no SWAT	166
A	PÊND	ICE B – Parâmetros de calibração utilizados no SWAT	168
A	PÊND	PICE C – Resultados completos de calibração e validação do modelo hidrológico e	de
pı	revisão	o de vazão para a BHPS	170
	Calib	ração e validação do modelo hidrológico	170
	Comp	paração entre as previsões de vazão bruta e probabilísticas	175
	Hidro	gramas de previsão da vazão máxima registrada	191
A pı	PÊND revisão	PICE D – Resultados completos de calibração e validação do modelo hidrológico e o de vazão para a BHRC	de 201
	Calib	ração e validação do modelo hidrológico	201
	Comp	paração entre as previsões de vazão bruta e probabilísticas	207
	Hidro	gramas de previsão da vazão máxima registrada	226

## 1 INTRODUÇÃO

No Brasil os eventos de inundação são o tipo de desastre natural com a maior frequência de registros. As inundações estão associadas ao maior número de perdas humanas e de grande impacto econômico. De acordo com a base de dados internacional de desastres EM-DAT (EM-DAT, 2019), desde a década de 70 mais de 19 milhões de pessoas foram afetadas pela ocorrência de inundações no Brasil.

Os sistemas de alerta hidrológico baseados em modelagem hidrológica são medidas importantes para mitigar os impactos sociais e econômicos da ocorrência de eventos de inundação (KOBIYAMA et al., 2004). Deste modo, o estudo de modelos para simular futuros impactos em recursos hídricos para diversas finalidades, entre elas a previsão hidrológica de inundações, deve ser estimulada, uma vez que o aprimoramento dos sistemas de previsão é importante para tornar mais eficiente a gestão de recursos hídricos (TUNDISI, 2014).

Entre as possíveis estruturas para previsão de inundações estão os modelos de previsão de vazão e/ou cotas, baseados em previsões de precipitação. Neste tipo de modelo, previsões atmosféricas, especificamente as previsões quantitativas de precipitação, são utilizadas para alimentar modelos hidrológicos (em geral modelos hidrológicos distribuídos, por permitirem representar a relação de causa e efeito do processo de transformação de chuva em vazão) e realizar previsões de vazões e/ou cotas (CUO; PAGANO; WANG, 2011; FAN, 2015). As previsões de vazão alimentadas com previsões quantitativas de precipitação serão denominadas neste trabalho como previsões hidrológicas de inundação.

As previsões atmosféricas podem ser agrupadas de acordo com o horizonte de tempo em que se estendem: Previsões que são realizadas com antecedência de algumas horas (normalmente não mais do que 6 horas) são chamadas de *nowcasting*; as previsões cuja antecedência vai de 6 horas até 48 horas são previsões de curto prazo; as previsões estendidas subsazonais ou de médio prazo são àquelas realizadas entre 2 dias até 40 dias, e; a previsão sazonal (também chamada climática) cujo horizonte de tempo é da ordem de 6 meses (CLOKE; SCHAAKE, 2016; CUO; PAGANO; WANG, 2011).

À medida que as previsões se estendem no tempo, a sensibilidade às condições iniciais e de contorno varia. Previsões de curto prazo são mais sensíveis às condições iniciais e, à medida que o horizonte de tempo aumenta, fatores remotos (como a variação da temperatura da

superfície do mar) ganham importância para explicação de variabilidades na escala interanual e intrasazonal (NATIONAL RESEARCH COUNCIL, 2002).

As previsões hidrológicas por conjunto possuem desempenho superior quando comparadas com previsões determinísticas (CLOKE; PAPPENBERGER, 2009) e permitem conhecer a incerteza associada às previsões, um fator importante para tomada de decisão operacional (ALFIERI et al., 2014).

Em previsões hidrológicas, modelos calibrados com dados observados são alimentados com previsões meteorológicas, mas essas previsões possuem erros diferentes dos dados observacionais. Isso pode gerar previsões hidrológicas enviesadas, tornando necessário aplicar técnicas de processamento para mitigar essas limitações. (WETTERHALL; SMITH, 2019).

Dentro deste contexto, a hipótese explorada neste trabalho é se o desempenho das previsões hidrológicas por conjunto pode ser melhorado com a aplicação de técnicas de processamento das previsões numéricas de precipitação. Espera-se com os resultados deste trabalho uma melhor compreensão sobre as potencialidades e limitações da realização de previsões hidrológicas por conjunto.

### 1.1 Objetivos gerais e específicos

O objetivo geral deste trabalho é implementar e validar uma metodologia de tratamento das previsões numéricas de precipitação por conjuntos para aplicação em sistemas de previsão de vazão, na bacia hidrográfica do Rio Paraíba do Sul (Trecho Paulista - SP) e na bacia hidrográfica do rio Caí (RS). Para atender ao objetivo geral, os seguintes objetivos específicos foram definidos:

i) Implementar um modelo hidrológico para representação dos processos hidrológicos nas bacias hidrográficas supracitadas;

ii) Realizar o processamento das previsões numéricas de chuva utilizando os métodos *Ensemble Model Output Statistics* e *Bayesian Model Average*;

v) Realizar experimentos de previsão hidrológica utilizando previsões numéricas de precipitação sem processamento e processadas para diferentes tempos de antecipação;

vi) Comparar o desempenho das previsões de vazão por conjunto brutas e processadas.

## 2 REVISÃO BIBLIOGRÁFICA

#### 2.1 Previsão meteorológica de precipitação por conjunto

A previsão numérica é um componente central da previsão atmosférica e o conceito base envolvido na previsão numérica de tempo é a solução de equações diferenciais parciais (EDPs) que regem o movimento e a evolução da atmosfera ao longo do tempo (KALNAY, 2003; PU; KALNAY, 2019). A previsão numérica é um problema de condição inicial no qual, conhecendose a condição atual da atmosfera (condição inicial) as EDPs que descrevem leis de conservação de momento, massa, energia e vapor d'água na atmosfera são integradas para obtenção dos estados futuros da atmosfera.

Deste modo, seria possível estabelecer duas condições fundamentais que devem ser satisfeitas para prever os estados futuros da atmosfera: A condição atmosférica presente deve ser tão bem caracterizada quanto possível e as leis que descrevem os estados atmosféricos subsequentes à condição presente devem ser bem conhecidas (BJERKNES, 1904 apud Pu, 2019, p. 68). Esta abordagem que considera que a previsão de estados futuros da atmosfera seria completamente definida a partir do conhecimento das condições iniciais e das equações que regem o comportamento da atmosfera é hoje conhecida como previsão determinística.

A primeira tentativa de resolver numericamente a atmosfera foi realizada sem sucesso por Richardson (RICHARDSON, 1922). Posteriormente, com o avanço de estudos para solução numérica de EDPs e com o início da computação, obteve-se sucesso nas primeiras previsões numéricas nos anos 50 (LYNCH, 2008). Alguns anos depois, foi constatado que o limite de previsibilidade da atmosfera não estava associado apenas com limitações de conhecimento das condições iniciais e do equacionamento do comportamento da atmosfera, mas também à limitação imposta devido à natureza caótica da atmosfera (KALNAY, 2003).

Ao longo do tempo diversos trabalhos constataram que a utilização de múltiplos membros apresenta resultados melhores do que uma única previsão determinística. Primeiramente, foram adicionadas perturbações nas condições iniciais dos modelos de previsão e atualmente foram incorporadas as incertezas associadas às parametrizações físicas dos modelos, de suas condições de contorno e concepção (YUAN et al., 2019). A abordagem de vários membros é conhecida como previsão por conjuntos ou por *ensembles*.

Atualmente, a principal base de informações sobre previsões por conjuntos, o *THORPEX Interactive Grand Global Ensemble* (TIGGE) armazena rodadas de previsões numéricas por conjunto de diversos centros de previsão do mundo. A Tabela 1 apresenta características dos principais sistemas de previsão por conjunto que fazem parte da base de dados do TIGGE. Nota-se que há diferenças entre os modelos, com horizonte de previsão variando de 10 a 16 dias, a resolução e o número de membros também varia de acordo com o modelo. Em relação ao método de perturbação inicial, a maioria dos modelos utiliza *Singular Vectors* e *Ensemble Kalman Filter*, com exceção do CMA e do CPTEC que utilizam *Breed* Vectors e *Empirical Orthogonal Functions* (EOF), respectivamente.

Centro de Previsão	Horizonte de previsão (dias)	Resolução [°]	N. de membros	Método de perturbação das condições iniciais
BMRC - Bureau of Meteorology Research Center (Austrália)	10	0.45° x 0.3°	33	Singular Vectors
CMA - China Meteorological Administration (China)	10	$0.5^{\circ} \ge 0.5^{\circ}$	30	Breed Vectors
CPTEC - Centro de Previsão do Tempo e Estudos Climáticos (Brasil)	15	0.9375° x 0.9375°	15	EOF-based perturbation
MSC – Meteorological Service of Canada (Canadá)	16	0.25° x 0.25°	21	Ensemble Kalman Filter
ECMWF - European Centre for Medium-Range Weather (Europa)	15	$0.5^{\circ} \ge 0.5^{\circ}$	51	Singular Vectors
JMA - Japan Meteorological Agency (Japão)	11	1.25° x 1.25°	51	Singular Vectors
KMA - Korea Meteorological Agency (Coréia do Sul)	10	0.5° x 0.5°	26	Ensemble Transform Kalman Filter
NCEP - National Centres for Environmental Prediction (EUA)	10	0.7° x 0.7°	20	Ensemble Transform Kalman Filter
UKMO - United Kingdom Met Office (Reino Unido)	15	0.187° x 0.28125°	18	Ensemble Transform Kalman Filter

Tabela 1 - Características dos principais sistemas de previsão numérica

Fonte: Yuan et al. (2019)

Apesar das diferenças apresentadas, os modelos que fazem parte do TIGGE utilizam integração numérica das equações que descrevem o comportamento da atmosfera. A formulação que se segue apresenta uma boa descrição geral de como as previsões por conjunto são geradas pela integração das equações do modelo a partir de condições iniciais perturbadas de acordo com a tendência esperada pelo modelo (BUIZZA et al., 2019).

De modo geral, uma previsão para um tempo T, no dia d é dada pela integração das equações do modelo atmosférico, estas equações consideram a tendência da atmosfera devido aos processos adiabáticos, a tendência associada à parametrização dos processos físicos, e a tendência de outros processos não resolvidos pelo modelo. Na maioria dos modelos cada integração para previsão se inicia da condição inicial, definida a partir da assimilação de um conjunto de dados observados (período de análise), e então são adicionadas uma perturbação à análise sem perturbação.

#### 2.2 Processamento das previsões numéricas de precipitação

As previsões numéricas de modelos atmosféricos podem ser tratadas para melhor representar condições locais e reduzir a discrepância entre as previsões e os valores observados in-situ. Na literatura os métodos de tratamento das previsões numéricas são referidos como "pós-processamento" ou "calibração" e podem ser classificados em três categorias: estatísticos, análogos e *downscaling* dinâmico (SENE, 2015).

Neste trabalho será utilizado o termo *processamento das previsões numéricas de modelos atmosféricos* com o significado de "um ou mais procedimentos que corrigem estatisticamente as previsões numéricas, com o objetivo de melhorar a acuidade, acurácia e confiabilidade das variáveis meteorológicas previstas quando comparadas com observações" (WETTERHALL; SMITH, 2019). Além dos termos previamente expostos, especificamente os modelos estatísticos também podem ser referidos como Estatísticas de Saída da Previsão de Tempo (geralmente referido pelo termo em inglês *Model Output Statistics* - MOS) (GLAHN; LOWRY, 1972; WETTERHALL; SMITH, 2019).

Em aplicações para previsão hidrológica os modelos hidrológicos são calibrados com dados observados e posteriormente alimentados com previsões numéricas de tempo. Nestas condições está sendo assumido que a base de dados observados e a base de dados de previsões numéricas de tempo se comportam de maneira semelhante e, consequentemente, geram respostas semelhantes na saída do modelo hidrológico. No entanto, esta consideração não é verdadeira quando há diferenças entre as bases de dados (WETTERHALL; SMITH, 2019).

Conforme apresentado, as previsões numéricas de tempo são inerentemente incertas, sendo que há fontes de incerteza, tais como erros nas observações assimiladas, parametrizações e

estrutura do modelo, estimativa de valores de parâmetros, condições iniciais, deficiências numéricas, entre outras (LI et al., 2017).

Assim, não se pode assumir que as previsões numéricas possuem a mesma estrutura de erros que os dados observacionais. A climatologia das previsões se difere dos dados observacionais o que pode implicar em viés nas previsões hidrológicas quando previsões são utilizadas para alimentar modelos calibrados com dados observados (BÁRDOSSY; DAS, 2008).

Ainda que a melhora dos produtos de previsão numérica do tempo tenham sido importantes para permitir o uso destes em aplicações hidrológicas (CLOKE; PAPPENBERGER, 2009; FAN et al., 2014; TOMASELLA et al., 2019; WU et al., 2020), o uso de técnicas de processamento das previsões deve continuar sendo uma alternativa para melhorar a qualidade das previsões, uma vez que o processamento das previsões numéricas pode reduzir a discrepância em relação às observações, removendo erros sistemáticos e produzindo previsões numéricas de tempo corrigidas, que são mais confiáveis (AMINYAVARI; SAGHAFIAN, 2019; ROBERTSON; SHRESTHA; WANG, 2013; SCHEUERER, 2014) e que melhor representam a estrutura original dos dados observados, implicando em redução do viés das saídas das previsões hidrológicas (WETTERHALL; SMITH, 2019).

Para realizar o processamento de variáveis meteorológicas, primeiramente é feita a coleta das observações e previsões brutas (saídas numéricas do modelo atmosférico) dos eventos de interesse. Então, uma parte do período de observações e previsões é utilizada para ajustar (treinar ou calibrar) uma distribuição de probabilidade que relaciona a previsões brutas com as observações (HAMILL; HAGEDORN; WHITAKER, 2008a; JAVANSHIRI; FATHI; MOHAMMADI, 2021). Posteriormente, é definida a distribuição de probabilidade para todos os eventos e, então, é possível conhecer a probabilidade de excedência de uma previsão bruta.

Diferentes saídas dos modelos meteorológicos podem ser processadas, entre elas a temperatura (HAMILL; HAGEDORN; WHITAKER, 2008a), evapotranspiração (MEDINA; TIAN, 2020) e a precipitação (HAMILL; HAGEDORN; WHITAKER, 2008b). Neste trabalho serão destacadas as aplicações de processamento das previsões de precipitação, uma vez que esta é a principal variável na ocorrência de inundações nas bacias estudadas e a principal forçante para geração de vazão do modelo hidrológico utilizado.

Em uma das primeiras aplicações de técnicas de processamento de precipitação houve melhora no desempenho das previsões de até dois dias para precipitações acumuladas de até 30 mm e de até 10 dias para precipitação de pequena intensidade, com acumulados de até 2 mm (ECKEL; WALTERS, 1998). Posteriormente, foi verificado que para precipitações intensas, o uso de períodos de treinamento maiores apresentou benefícios para eventos de precipitação intensa em previsões com horizontes de tempo de até 5 dias (HAMILL; HAGEDORN; WHITAKER, 2008b).

Na literatura recente, os métodos EMOS (*Ensemble Model Output Statistics*) e BMA (*Bayesian Model Average*) tem se destacado como boas alternativas para o processamento de previsões de precipitação por conjunto (JAVANSHIRI; FATHI; MOHAMMADI, 2021; SCHEUERER, 2014; SLOUGHTER et al., 2007).

No método EMOS a precipitação é ajustada em uma única função densidade de probabilidade (FDP), que tem seus parâmetros estimados com base na distribuição dos membros do conjunto das previsões numéricas de precipitação em função das observações para o período de treinamento (GNEITING et al., 2005). O modelo BMA também produz previsões probabilísticas geradas a partir do ajuste de uma FDP às previsões numéricas de precipitação. Porém, no modelo BMA cada um dos membros é ajustado à uma FDP, e a distribuição de probabilidade final é dada pela combinação das FDPs dos membros, que podem ainda ser ponderadas pelo peso de cada membro (RAFTERY et al., 2005).

Uma etapa importante no processamento das previsões de precipitação é a configuração do método de treinamento. O treinamento pode ser realizado por divisão da amostra, por períodos ou utilizando uma janela móvel. No treinamento por divisão da amostra, parte da amostra disponível de pares observação-previsão é utilizada para treinamento e o restante para avaliação. No treinamento por períodos, são utilizadas amostras que podem ser sazonais ou mensais, sendo geradas diferentes parametrizações que serão empregadas no período de avaliação de acordo com o período sazonal ou de acordo com o mês avaliado, respectivamente. Pode ser gerado, por exemplo, uma parametrização para meses chuvosos e outra para meses secos, ou para cada mês do ano entre outras possibilidades. Tanto a divisão da amostra quanto o treinamento por períodos, possuem a vantagem do uso de séries maiores e que são estatisticamente mais robustas e menos influenciadas pela variabilidade de curto prazo (GNEITING et al., 2005; HAMILL; HAGEDORN; WHITAKER, 2008a).

Alternativamente, o treinamento pode ser realizado utilizando uma janela móvel com tamanho (intervalo de tempo) que se desloca acompanhando os eventos de interesse e neste caso o ajuste das FDP's utilizadas no processamento é dinâmico e a parametrização se altera em cada passo temporal. A vantagem da janela móvel está em acompanhar as precipitações observadas mais recentes para realizar a parametrização dos modelos probabilísticos, se adaptando melhor a tendências e se adaptando rapidamente à mudanças nas condições ambientais (GNEITING et al., 2005; JAVANSHIRI; FATHI; MOHAMMADI, 2021). A desvantagem é que a definição da janela pode ser subjetiva e variar de acordo com o horizonte de tempo ou com o modelo probabilístico utilizado e também aumentar o custo computacional, uma vez que é realizado um ajuste para cada passo de tempo (GNEITING et al., 2005).

Ainda que promovam melhoras na qualidade da previsão, há na literatura poucos trabalhos que avaliam o uso de previsões numéricas de precipitação processadas como entradas para alimentar os modelos hidrológicos e os resultados não são consensuais.

A comparação entre o uso da BMA para o processamento das previsões meteorológicas, com as previsões brutas (sem processamento) e com as previsões de vazão pós-processadas (aplicação da BMA na saída de vazão do modelo hidrológico) para 19 bacias da Noruega, mostra que o processamento aumentou a capacidade de antecipação da previsão (HEGDAHL et al., 2023).

Resultado diferente foi obtido para uma bacia da Dinarmaca, onde o pós-processamento da vazão se mostrou uma melhor alternativa para melhora da previsão de vazão em escala sazonal do que o processamento das previsões numéricas de tempo, uma vez que o primeiro contorna melhor problemas de condição inicial no modelo hidrológico (LUCATERO et al., 2018).

A correção de viés da previsão numérica de precipitação do ECMWF, tanto por regressão linear quanto por ajuste em funções de distribuição de probabilidade, melhorou o desempenho das previsões hidrológicas em escala sazonal quando comparadas com as previsões brutas em 16 bacias hidrográficas da França (CROCHEMORE; RAMOS; PAPPENBERGER, 2016).

Uma comparação entre as previsões de vazão geradas a partir das previsões numéricas brutas do GEFS, previsões numéricas do GEFS processadas e vazão de saída do modelo hidrológico pós-processadas, mostram que tanto o processamento das previsões numéricas de precipitação quanto o pós-processamento da vazão prevista, melhoram a qualidade da previsão quando comparadas com a previsão bruta, no entanto o resultado do pós-processamento da vazão se mostrou a alternativa mais competitiva na bacia do Rio Susquehanna no nordeste dos Estados Unidos (SHARMA et al., 2018).

Em uma análise que quantificou as diferentes fontes de incerteza ao longo do esquema de previsão hidrológica para 30 bacias canadenses, os resultados mostram que o uso de previsões atmosféricas processadas para alimentar o modelo hidrológico melhora o desempenho das previsões hidrológicas quando comparada com o modelo hidrológico alimentado com previsões brutas, contudo, o resultado é ainda melhor quando feita a combinação de previsões numéricas processadas com as incertezas do modelo hidrológico. Este resultado sugere que parte do benefício promovido pelo processamento das previsões numéricas pode ser cancelado ou perdido ao longo da cadeia de simulação hidrológica (VALDEZ; ANCTIL; RAMOS, 2022).

Diferentes técnicas estatísticas foram utilizadas para o processamento das previsões numéricas de precipitação oriundas de vários centros de previsão do tempo e todas as técnicas apresentaram desempenho superior ao uso de previsões brutas para representação de cheias ocasionadas por tempestades severas na bacia do rio Dez, no Irã (TANHAPOUR et al., 2023).

#### 2.3 Modelagem hidrológica

Modelos hidrológicos são utilizados para representar o comportamento físico, químico ou biológico de bacias hidrográficas e reproduzir processos hidrológicos. Formalmente, modelos hidrológicos podem ser divididos em duas categorias: os modelos físicos (ou de laboratório) e os modelos matemáticos. A primeira se refere aos protótipos de bacias feitos para replicar os processos hidrológicos da bacia e a segunda categoria se refere aos modelos matemáticos que descrevem quantitativamente os processos hidrológicos por meio de equações, condições iniciais e de contorno que expressam as relações entre entrada e saída do modelo (JAIN; SINGH, 2019). Neste trabalho, serão referidos como modelos hidrológicos os modelos da segunda categoria.

Os modelos hidrológicos podem ser modelos concentrados, que apresentam base física, mas que não consideram sua variação espacial, ou distribuídos, com alto grau de detalhamento dos processos hidrológicos que ocorrem dentro de uma bacia hidrográfica (COLLISCHONN, 2001).

Os primeiros trabalhos de modelagem hidrológica se iniciam na década de 60, com o desenvolvimento dos modelos Stanford Watershed IV (CRAWFORD; LINSLEY, 1966) e

Sacramento (BURNASH; FERRAL; MCGUIRE, 1973) que contabilizam explicitamente a umidade do solo e representam as conexões entre os processos hidrológicos que podem gerar respostas na bacia hidrográfica. No final dos anos 70, foram introduzidos modelos concentrados que representam o processo de transformação de chuva em vazão como um processo Dunniano, com escoamento superficial gerado a partir da saturação das camadas superficiais do solo. Os modelos ARNO e PDM são exemplos desta categoria (TODINI, 2011). Posteriormente, a informação relativa à topografia da bacia foi acrescentada nos modelos hidrológicos com o modelo TOPMODEL (BEVEN; KIRKBY, 1979).

Com o objetivo de melhor representar os processos físicos que ocorrem na bacia hidrográfica, começaram a ser desenvolvidos modelos hidrológicos capazes de representar as variações espaciais das características da bacia. Neste caso a bacia pode ser discretizada e são utilizadas equações diferenciais parciais para descrever o escoamento em superfície e subsuperfície, que podem ser integradas numericamente e resolvidas considerando condições de contorno. Em alguns casos, como o modelo SHE (ABBOTT et al., 1986) a quantidade de informação necessária para representar a bacia pode comprometer a aplicação do modelo em áreas em que as informações são limitadas (TODINI, 2011).

A maioria dos modelos distribuídos e de base física foi desenvolvida para solucionar problemas de engenharia usuais em pequenas bacias (da ordem de 100 a 1000 km<sup>2</sup> de área) como determinação de cotas de inundação, dimensionamento de pontes e reservatórios, entre outros (LINSLEY; KOHLER; PAULHUS, 1982) e diante desta questão, mais recentemente foram desenvolvidos modelos hidrológicos distribuídos capazes de representar o processo de transformação de chuva em vazão em grandes bacias (COLLISCHONN, 2001) e modelos originalmente pensados para bacias menores foram adaptados para simulação de grandes bacias (ABOU RAFEE et al., 2019).

#### 2.4 Previsão hidrológica por conjunto

Uma das primeiras aplicações consideradas como previsão hidrológica probabilística gerada por conjuntos foi realizada nos anos 70 pelo Serviço de Meteorologia dos Estados Unidos (NWS). Neste modelo, os dados históricos de precipitação e temperatura eram utilizados como forçantes (entradas) para um modelo hidrológico com as condições iniciais atuais. Esta abordagem assume que cada ano dos dados históricos de temperatura e precipitação seria uma possível representação do futuro para gerar previsões probabilísticas (DAY, 1985).

Os primeiros trabalhos utilizando conjuntos de previsões numéricas de precipitação para previsão de vazão datam do início do ano 2000 e se tornam mais populares a partir de 2010, quando os produtos dos sistemas de previsão meteorológica por conjunto se tornam mais acessíveis para o público geral (WU et al., 2020). O uso de previsões numéricas de precipitação para previsões hidrológicas por conjunto foi impulsionado pelo início dos trabalhos do *Hydrological Ensemble Prediction Experiment* (HEPEX) em 2004, com a implementação do Hydrological Ensemble Forecast System (HEFS) pelo *US National Weather Service* (NWS) em 2010, utilizando técnicas de pré-processamento das previsões meteorológicas, permitiu realizar previsões hidrológicas em diferentes escalas espaciais e temporais (CLOKE; SCHAAKE, 2016).

Diversos sistemas de previsão hidrológica de inundação por ensemble descritos na literatura são utilizados operacionalmente ou estão em fase pré-operacional (WETTERHALL et al., 2013). O *European Flood Awareness System* (EFAS) é um importante sistema em fase operacional que disponibiliza mapas de probabilidade de inundação com antecipação de 3 a 10 dias, este horizonte de previsão é possível graças a incorporação de previsões meteorológicas de médio alcance do *Deutscher Wetterdienst* (DWD) e do ECMWF. O conjunto de diferentes hidrogramas é analisado e combinado para produzir informações de alerta de inundação, que são enviadas para os serviços hidrológicos que participam do sistema (THIELEN et al., 2009; BARTHOLMES et al., 2009).

Desenvolvido no NWS o *Hydrologic Ensemble Forecast Service* (HEFS) modela a incerteza total das previsões hidrológicas. As entradas são pré-processadas para correção de vieses e cálculo da covariabilidade espaço-temporal utilizando o método Schaake Shuffle (DEMARGNE et al., 2014). As forçantes oriundas dos modelos meteorológicos incluem previsões de temperatura e precipitação do Global Ensemble Forecast System (GEFS) e do

Climate Forecast System (CFSv2 do NCEP), entre outros. O HEFS está sendo implementado em fases e testado para uso operacional em 2015–2016 em escritórios do NWS (CLOKE; SCHAAKE, 2016).

As previsões numéricas de precipitação do ECMWF também foram utilizadas para subsidiar um sistema de previsão hidrológica de inundações em uma região abaixo do nível do mar no delta do rio Reno (Holanda). Acoplado com modelos hidrodinâmicos o sistema, em fase pré-operacional, tem como objetivo otimizar a operação de bombas hidráulicas para minimizar os efeitos de inundações (VAN ANDEL et al., 2014).

Na bacia do rio Gatineau, sudeste do Canadá, previsões por conjunto utilizadas em sistema de apoio a tomada decisão do setor elétrico durante eventos de cheia, mostraram que as previsões por conjunto foram melhores do que as determinísticas em termos de produção de eletricidade, redução de vertimentos e prevenção de inundações (BOUCHER et al., 2012).

Em operação desde 2005 o sistema de alerta do rio Po no norte da Itália utiliza diferentes modelos hidráulicos e hidrológicos (Sistema HEC e Mike11) e é forçado com previsões numéricas de precipitação oriundas de diferentes modelos (COSMOI2, COSMOI7, COSMO-LEPS), além de observações de precipitação e possibilitam a antecipação de eventos com até cinco dias de antecedência (RICCIARDI et al., 2013).

O benefício econômico do uso de previsões probabilísticas de inundação foi avaliado na bacia do rio White Cart Water, na Escócia, e mostra que previsões probabilísticas resultam em diminuição dos riscos de inundação quando comparado com um sistema baseado em previsões determinísticas e ainda que a maximização da performance econômica dos sistemas de alertas não dependem exclusivamente do aumento da capacidade de antecipação dos eventos, mas sim de uma combinação entre custo de emissão dos alertas e incerteza associada com a previsão (VERKADE; WERNER, 2011).

Para evitar o impacto de inundações severas em Zurique (Suíça) o sistema de previsão da bacia do rio Sihl utiliza novas maneiras de exibir mapas de persistência e previsões defasadas. Neste sistema, é realizado o downscaling dinâmico das previsões do ECMWF para região de interesse (resolução de ~50 km para 7~km), dos membros previamente selecionados como representativos da região de interesse (ADDOR et al., 2011).

O sistema de previsão de inundações africano (acrônimo em inglês – AFFS) tem como objetivo fornecer previsões probabilísticas para todo o continente africano. O modelo Lisflood é

alimentado com as previsões numéricas de precipitação do ECMWF para horizontes de tempo de até 15 dias. Durante o ano de 2003 (notadamente um ano de muitos eventos de inundação no continente) o sistema permitiu a detecção de cerca de 70% dos eventos de inundação ocorridos no período (THIEMIG et al., 2015).

Na América do Sul, trabalhos de previsão hidrológica por conjunto são relativamente mais recentes e existe proporcionalmente menos estudos quando comparado com outras regiões do globo (WU et al., 2020).

Um dos primeiros experimentos de previsões hidrológicas por conjunto em bacias brasileiras foi realizado na bacia do rio Paraopeba. Neste estudo, o uso de diferentes modelos de previsão numérica de precipitação para realização de previsões por conjunto, possibilitou previsões com maior capacidade de antecipação de eventos de cheia, quando comparada com previsões determinísticas (MELLER, 1996).

Na bacia do rio Grande onde foram avaliados horizontes de previsão de 1 a 10 dias utilizando previsões numéricas do modelo ETA e previsões de até 6 meses utilizando o modelo AGCM do CPTEC. As previsões de até 12 dias se mostraram úteis para aplicações operacionais na bacia quando comparadas com o sistema utilizado à época pelo Operador Nacional do Sistema (TUCCI et al., 2009).

Os membros do conjunto gerados a partir de combinações de previsões do WRF foram utilizados como forçante no modelo hidrológico TopModel para simulação de diversos eventos de cheia na bacia do rio Iguaçu. Os resultados mostram que a previsão por conjuntos melhora a capacidade de previsão da maioria dos eventos simulados (CALVETTI, 2011)

Experimentos de previsão por conjunto na bacia amazônica mostram que a incerteza nas condições iniciais da bacia é importante na qualidade da previsão, mesmo em horizontes de tempo maiores. As condições iniciais de nível da água são as maiores fontes de incerteza, enquanto que as condições iniciais de umidade do solo possuem importância relativa e mais pronunciada na parte sudeste da bacia e as forçantes meteorológicas são mais importantes no início da estação chuvosa, na parte sudeste da bacia (PAIVA et al., 2012).

O conjunto de previsões denominado *Global Ensemble Forecast System* (GEFS), provido pelo *National Oceanic and Atmospheric Administration* (NOAA), e as previsões determinísticas do modelo ETA provido pelo CPTEC foram avaliados para previsão de inundação na bacia do rio Tocantins. A previsão por conjuntos se mostrou vantajosa quando comparada com a previsão determinística (FAN et al., 2016).

As previsões por conjuntos do GEFS também se mostraram como uma interessante alternativa quando comparada com previsões determinísticas do mesmo modelo (média dos membros e membro controle) para previsões de inundação na bacia do rio São Francisco, principalmente para previsão de vazões afluentes em reservatórios durante eventos de inundação (FAN et al., 2014).

O desempenho dos conjuntos do ECMWF, GEFS e CPTEC foram comparados nas bacias dos rios São Francisco, Tocantins e Doce. O desempenho do GEFS foi melhor em relação aos demais na bacia do Tocantins enquanto que os resultados utilizando o conjunto do ECMWF se mostrou mais consistente nas bacias dos rios Doce e São Francisco (FAN et al., 2015).

O conjunto do ECMWF foi utilizado para realização de previsões hidrológicas que por sua vez serviram de subsídio para um modelo de otimização de operação do reservatório de Três Marias, na bacia do rio São Francisco. De acordo com os autores o método tem vantagens quando comparado com os métodos comumente usados para tomada de decisão de curto prazo, uma vez que as previsões probabilísticas permitiram ampliar o horizonte de previsão, a otimização estocástica leva a decisões mais robustas do que procedimentos determinísticos que consideram apenas uma única trajetória futura e também permitiu introduzir restrições de chance avançadas para refinar a operação do sistema (SCHWANENBERG et al., 2015).

Experimentos de previsão por conjunto na bacia do rio Taquari-Antas mostrou que a vazão máxima foi bem prevista por ao menos um dos cinco membros gerados a partir do modelo regional ETA (SIQUEIRA et al., 2016). As previsões por conjunto, ainda que com um número bastante limitado de membros, melhoram a probabilidade de detecção do sistema.

O desempenho de previsões hidrológicas por conjunto para a bacia do rio Itajaí-Açu é útil para aplicações operacionais no horizonte de previsão de até 48 horas (CASAGRANDE et al., 2017).

O uso dos conjuntos do ECMWF e ETA para previsões hidrológicas de inundação na bacia do rio Doce trouxe benefícios para a previsibilidade de enchentes na bacia, mostrando que a forma e orientação das sub-bacias influenciam na capacidade de previsão e que o conjunto do ECMWF possui melhor desempenho para bacias maiores, enquanto que o ETA melhorou a capacidade de previsão em bacias menores (TOMASELLA et al., 2019).
O conjunto do ECMWF também foi utilizado para previsões hidrológicas na bacia do Paraná (QUEDI; FAN, 2020) em horizonte de tempo sub-sazonal. Nesse trabalho, o uso de previsões numéricas de precipitação por conjunto mostrou que o desempenho foi superior ao da previsão determinística de referência e da abordagem de previsão estendida, baseada no histórico de eventos pretéritos.

Uma avaliação em escala continental na América do Sul, utilizando o conjunto do ECMWF, mostra que nas regiões mais a leste e sudeste do continente o potencial de aplicação de previsões por conjunto para previsões de inundação com horizonte temporal de até 15 dias (SIQUEIRA et al., 2020).

Um ponto importante a ser destacado é que maior parte dos trabalhos de previsão por conjunto trata de bacias de mesoescala, onde a interação entre as condições antecedentes é uma importante variável a ser considerada para capacidade de previsão dos sistemas, sendo pouca atenção dada à composição dos eventos de inundação (WU et al., 2020). A maior parte dos trabalhos também não discute a aplicação de técnicas de processamento probabilístico das previsões de precipitação, que são a principal forçante dos modelos hidrológicos, sendo este um tema pouco explorado na literatura (WU et al., 2020).

# **3** METODOLOGIA

Neste capítulo é apresentada a metodologia utilizada neste trabalho. O primeiro tópico trata da metodologia para a modelagem hidrológica. No item seguinte é abordada a metodologia e os dados utilizados para processamento e avaliação das previsões de precipitação. O último item da metodologia trata da configuração dos experimentos de previsão de vazão, da correção da vazão prevista e das métricas utilizadas para avaliação dos experimentos de previsão de vazão. A figura 1 apresenta um fluxograma com as principais etapas da metodologia.



Figura 1 – Fluxograma com os passos gerais da metodologia desenvolvida neste trabalho

Fonte: elaborado pelo autor

# 3.1 Modelagem Hidrológica

A modelagem hidrológica pode ser dividida em três fases. A primeira delas, denominada pré-processamento, compreende a adequação dos dados de entrada necessários para simulação hidrológica e compreendeu as seguintes etapas:

- Processamento do modelo digital de elevação (MDE) para obtenção das direções do fluxo, rede de drenagem, área da bacia e minibacias;
- Definição das unidades de resposta hidrológica (URH) a partir das informações de cobertura da superfície, tipos de solo e declividade do terreno;
- Parametrização inicial das URH;
- Adequação do formato dos dados de variáveis meteorológicas requeridos pelo modelo SWAT (precipitação, temperatura mínima e máxima diária, umidade relativa, radiação incidente na superfície e vento).

Após o pré-processamento foi realizada a análise de sensibilidade do modelo. O objetivo da análise de sensibilidade foi verificar quais parâmetros de calibração possuem maior influência na saída do modelo. No caso deste trabalho, a saída de interesse é a vazão simulada diária. Tanto a análise de sensibilidade quanto à calibração do modelo foram realizadas utilizando o pacote R-SWAT (NGUYEN et al., 2022). Entre as opções de algoritmo de calibração disponíveis, foi selecionado o algoritmo SUFI-2, amplamente documentado na literatura para calibração do modelo SWAT (ABBASPOUR et al., 2007).

Após a calibração, foi realizada a verificação do modelo. Na etapa de verificação, o modelo é rodado utilizando a parametrização obtida no período de calibração, mas utilizando um período diferente. O objetivo da verificação é avaliar se o conjunto de parâmetros obtidos na calibração mantém a capacidade de representação do comportamento hidrológico da bacia em período diferente daquele utilizado para calibração.

O próximo item descreve as bases de dados e os itens subsequentes abordam a sequência de passos envolvida na modelagem hidrológica.

## **3.1.1 Dados utilizados**

Foi utilizado o modelo digital de elevação SRTM (*Shuttle Radar Topography Mission*) com resolução horizontal de 30 m (NASA, 2013). As informações de cobertura da superfície foram extraídas da coleção 6 do Mapbiomas (MAPBIOMAS, 2020). A informação de tipo de solo foi obtida na base de dados de solos do Brasil do IBGE (IBGE, 2020).

Os dados de temperatura mínima e máxima diária, umidade relativa, radiação incidente na superfície e vento foram obtidos a partir de dados de reanálise do NCEP (*National Centers for Environmental Prediction*) adaptados para uso no modelo SWAT com resolução espacial de 0.25° x 0.25° e temporal de 24 horas (FUKA et al., 2014).

Para representação do campo de precipitação observada na bacia foi utilizado o produto *Multi-Source Weighted-Ensemble Precipitation* (MSWEP). O MSWEP (versão 2.2) é uma base de dados de precipitação global com resolução espacial de 0.1° e temporal de 3 horas. A partir da versão 2 passou a utilizar sete fontes de informação sobre precipitação: duas de observações de superfície (CPC Unified e GPCC), três de imagens de satélites (CMORPH, GSMaP e TMPA 3B42RT) e duas de reanálise de modelos (ERA-Interim e JRA-55) e, entre os produtos de precipitação disponíveis, é o que melhor representa a precipitação nas áreas de interesse (BECK et al., 2019; CAPOZZOLI; FUJITA; FREITAS, 2021).

Os períodos utilizados e a base de dados de vazão utilizados serão especificados nos itens de cada área de estudo, uma vez que há diferença entre as bases de dados disponíveis.

#### 3.1.2 Pré-processamento

Para determinação da rede drenagem e delimitação das bacias e sub-bacias, foi feita a correção da drenagem do MDE rebaixando as elevações das células de grade do MDE que coincidem com a linha de drenagem da hidrografia (queima da drenagem). Como referência de drenagem foi utilizada a hidrografia disponibilizada pela Agência Nacional de Águas (ANA, 2012), verificadas com imagens de satélite do Google Earth.

Uma vez definida a drenagem da bacia, a mesma foi discretizada em minibacias. As minibacias são pequenas sub-bacias onde o SWAT realiza o balanço hídrico e considera as informações de entrada atmosférica homogênea em toda área. Considerando que a distribuição espacial da precipitação é a forçante mais importante do modelo, foi utilizada a máxima

discretização possível para cada bacia, incluindo ainda exutórios de minibacias em pontos coincidentes com os pontos de monitoramento fluviométrico.

As URHs são geradas pelo cruzamento das informações de superfície, tipos de solo e classes de declividade de relevo. A informação de cobertura da superfície do Mapbiomas foi reclassificada agrupando as classes que possuem características semelhantes. Por exemplo, as diferentes classes de floresta foram agrupadas em uma única classe (FRSE). Os parâmetros iniciais das classes de cobertura foram mantidos os mesmos do banco de dados do SWAT.

Originalmente, o modelo permite que o índice de área foliar (IAF) varie ao longo das simulações considerando as condições de temperatura e umidade. Esta configuração pode ser alterada configurando um esquema de operação no qual são indicados os valores de IAF para cada classe de cobertura, em cada um dos meses do ano (os valores de IAF são indicados na tabela A2 do anexo A).

Em função da variada gama de aplicações, o SWAT possui uma série de parâmetros associados às classes de cobertura de superfície e de tipo de solo, sendo que nem todos os parâmetros influenciam na geração de escoamento do modelo. Deste modo, a descrição que se segue será limitada aos parâmetros de cobertura da superfície que são relevantes para geração de escoamento:

 CN2: Valor da curva número do Soil Conservation Service (SCS) para condição de umidade II. Este parâmetro controla o valor de CN na condição de umidade média (umidade II). Para cada classe de cobertura o SWAT armazena quatro possíveis valores para CN2 sendo adotado aquele correspondente à classe hidrológica do solo (A, B, C, D). No exemplo ilustrado na Tabela 2, a cobertura FRSE adotará CN2 = 25 caso a cobertura esteja sobre um solo pertencente ao grupo hidrológico A e CN2 = 77 caso o solo sobre a qual a cobertura está assentada pertença ao grupo D. Coberturas com melhor permeabilidade tendem a ter valor de CN2 menor.

Tabela 2 – Exempl	o de valores	de CN2	(valor da	l curva	número	do SC	'S para	condição	de de	umidade	II)	para so	los de
diferentes grupos h	idrológicos (	A, B, C e	e D) extra	aído do	banco d	e dado	s dispo	onível no l	SW	AT			

Cobertura		CN	N2	
	Α	В	С	D
FRSE	25	55	70	77

- OV\_N: Coeficiente de Manning para escoamento superficial. Parâmetro associado à rugosidade da superfície. Superfícies mais polidas, por exemplo, asfalto ou concreto, possuem OV\_N menor do que superfícies mais rugosas, como um campo gramado.
- CANMX: Máximo armazenamento de água no dossel. No SWAT este armazenamento é definido de acordo com o índice de área foliar do tipo de cobertura. Neste trabalho o índice de área foliar foi definido variando de acordo com a sazonalidade da bacia (COLLISCHONN, 2001).
- ESCO: Coeficiente de compensação da evaporação do solo. Este coeficiente permite que a demanda evaporativa da bacia seja compensada extraindo água de porções mais profundas do solo.
- SLSUBBSN: Declive médio. Este parâmetro define o declive médio para o trecho da URH. O
  declive médio é utilizado para definição do tempo de concentração da bacia.
- LAT\_TTIME: Tempo de percurso do escoamento lateral.

Especificamente para as coberturas de áreas urbanas há ainda os seguintes parâmetros que são relevantes para o cálculo do escoamento superficial nestas áreas:

- URBCN2: Valor da curva número do SCS para condição de umidade II na fração impermeável da área urbana.
- FIMP: Fração impermeabilizada da área urbana
- FCIMP: Fração impermeabilizada que é hidraulicamente conectada à drenagem

Os valores adotados em cada bacia, bem como a reclassificação da cobertura do Mapbiomas para as classes de uso da base do SWAT, serão tratados individualmente no capítulo correspondente à modelagem de cada bacia. Além dos parâmetros de cobertura da superfície, há também parâmetros associados aos tipos de solo que são importantes para geração de escoamento no SWAT.

- NLAYERS: Número de camadas do solo. Este parâmetro interfere na capacidade de armazenamento em subsuperfície e consequentemente na geração de escoamento superficial. O número de camadas pode variar de 1 a j camadas, sendo j definido pelo usuário de acordo com as características do perfil de solo da área.
- HYDGRP: Grupo hidrológico do solo. Conforme apresentado anteriormente, de acordo com o grupo hidrológico será adotado o valor de CN2 para superfície.
- SOL\_ZMX: Profundidade máxima das raízes no solo. A profundidade vai limitar a região que a vegetação pode acessar para buscar água e influenciar a quantidade de água no solo.
- SOL\_Zj: Espessura da j-ésima camada de solo. Também relacionado com o volume de água que a camada é capaz de armazenar.
- SOL\_AWCj: Capacidade de armazenamento de água do solo da j-ésima camada. Dada pela diferença entre a umidade do solo saturado e na capacidade de campo.
- SOL\_Kj: Condutividade hidráulica do solo saturado na j-ésima camada. A condutividade hidráulica do solo define a resistência ao movimento da água na camada de solo.

O relevo foi subdividido em duas classes de declividade: até 5% de declividade e acima de 5% de declividade. Esta subdivisão foi feita para permitir que o modelo aceite valores de CN2 diferentes para um mesmo tipo de combinação cobertura-solo de acordo com a classe declividade. Este ajuste é necessário uma vez que os valores iniciais de CN2 da base de dados do SWAT consideram declividade de até 5% (NIETSCH et al., 2009).

Destaca-se que o SWAT resolve a precipitação na minibacia pelo método do vizinho mais próximo. Ou seja, a precipitação na minibacia corresponde à precipitação no ponto de monitoramento com a menor distância geométrica do centroide da minibacia. Os dados de precipitação do MSWEP foram previamente interpolados para os centroides das minibacias, sendo esta interpolação realizada pelo inverso do quadrado da distância, uma vez que este tem se mostrado mais eficiente na representação do campo de precipitação em modelagem com o SWAT (SZCZEŚNIAK; PINIEWSKI, 2015).

O banco de dados do SWAT foi atualizado para incluir os tipos de solos específicos de cada uma das sub-bacias. As características dos tipos de solo relevantes para o processo de

transformação de chuva em vazão foram atualizadas de acordo com Pereira et al. (2016) e Rafee et al. (2019) e estão disponíveis no anexo A.

Além dos parâmetros de solo e de superfície, o SWAT possui parâmetros importantes para geração do escoamento que estão relacionados com o fluxo de água subterrânea:

- ALPHA\_BF: Constante de recessão do escoamento de base. Este parâmetro é importante para o controle da vazão de base dos cursos d'água.
- GW\_DELAY: Tempo para recarga do aquífero. De acordo com o tempo para recarga do aquífero será definida a vazão no aquífero e o armazenamento no aquífero raso.
- GW\_REVAP: Coeficiente de *revap*. O SWAT define como *revap* o movimento ascendente de água, que ocorre quando a camada mais acima está insaturada. De acordo com o valor deste coeficiente, haverá retirada de água do aquífero para ser disponibilizada nas camadas mais superficiais.
- GWQMN: Limiar para recarga no canal principal. Este parâmetro delimita o nível da água no aquífero para que haja contribuição do aquífero para o curso d'água.
- RCHRG\_DP: coeficiente de percolação. O valor do coeficiente de percolação é importante para definição da fração da recarga diária no aquífero irá percolar para o aquífero profundo.
- ALPHA\_BNK: coeficiente da zona de armazenamento. Durante a ocorrência de inundações parte da água abastece o aquífero e o contrário ocorre durante a recessão. A zona de armazenamento se refere ao trecho subsuperficial ao longo do curso d'água onde ocorre esta troca. O coeficiente da zona de armazenamento define a proporção de troca do volume armazenado nesta zona.
- CH\_N2: Coeficiente de Manning do canal. Associado com a rugosidade do canal.
- EPCO: Fator de compensação da absorção de água. Este fator é usado para corrigir a quantidade de água disponível para vegetação.
- SURLAG: Coeficiente de atraso no escoamento superficial. Este coeficiente define, junto com o tempo de concentração, o máximo de escoamento que chega ao canal no intervalo de um dia.
- REVAPMN: Limite do nível d'água do aquífero para que ocorra a *revap*. A ocorrência de movimento ascendente de água depende do valor deste parâmetro.

## 3.1.3 Análise de sensibilidade

A análise de sensibilidade tem como objetivo compreender quais parâmetros são mais relevantes para a calibração do modelo hidrológico. A sensibilidade de cada parâmetro é calculada utilizando o sistema de regressão múltipla mostrado na equação 1. Dentro do intervalo de variação proposto para o parâmetro ( $b_i$ ), os valores são amostrados pelo método do hipercubo latino (MCKAY, 1992), e então realizada a regressão linear em relação aos valores da função objetivo (g) (ABBASPOUR et al., 2015):

$$\boldsymbol{g} = \boldsymbol{\alpha} + \sum_{i=1}^{m} \boldsymbol{\beta}_{i} \boldsymbol{b}_{i}$$
(Equação 1)

O teste-t é então usado para identificar a significância relativa de cada parâmetro  $b_i$ . A medida de sensibilidade dada pela equação 1 é uma estimativa das mudanças médias na função objetivo (g) resultantes de mudanças em cada parâmetro, enquanto todos os outros parâmetros também estão variando. Este método fornece a sensibilidade relativa com base em uma aproximação linear que eventualmente pode não representar completamente a sensibilidade da função objetivo em relação aos parâmetros do modelo. Além disso, é conveniente destacar que a sensibilidade relativa de diferentes parâmetros, conforme indicado pelo teste-t, depende dos intervalos dos parâmetros. Deste modo, a classificação dos parâmetros sensíveis pode mudar a cada iteração e isto será importante durante a calibração do modelo (ABBASPOUR et al., 2015).

A análise de sensibilidade foi realizada considerando todos os parâmetros potencialmente relevantes para o processo de transformação de chuva em vazão (tabela 3). Em todas as bacias foram utilizados os parâmetros e a faixa de variação da tabela 3 considerando uma iteração de 500 simulações. A variação do valor do parâmetro pode ser relativa (o novo valor é calculado em função do valor inicial) ou absoluta (o novo valor do parâmetro oscila dentro de um intervalo absoluto).

Tabela 3 – Parâmetros utilizados para análise de sensibilidade e seus respectivos valores iniciais. Para o tipo de mudança "Valor", o valor inicial é substituído por valores dentro do intervalo especificado e para mudança relativa o

Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo
ALPHA_BF.gw	Valor	0.01	1
ALPHA_BNK.rte	Valor	0.01	1
CANMX.hru	Valor	0	100
CH_N2.rte	Valor	0.01	0.3
CN2.mgt	Relativa	-0.9	0.9
EPCO.bsn	Valor	0.01	1
ESCO.hru	Valor	0.01	1
GW_DELAY.gw	Valor	1	365
GW_REVAP.gw	Valor	0.02	0.2
GWQMN.gw	Valor	0	5000
RCHRG_DP.gw	Valor	0	1
SOL_K().sol	Relativa	-0.9	0.9
SOL_AWC().sol	Relativa	-0.9	0.9
SURLAG.bsn	Valor	0.1	24
SLSUBBSN.hru	Relativa	-0.5	0.5
OV_N.hru	Valor	0.01	30
REVAPMN.gw	Valor	0	1000
LAT_TTIME.hru	Valor	0	10

valor inicial é multiplicado por 1+ r, em que r é um valor no intervalo especificado.

O resultado da análise de sensibilidade mostra os parâmetros que possuem maior impacto na vazão simulada. Neste trabalho foram considerados sensíveis para calibração os parâmetros cuja mudança promovida em relação aos demais parâmetros é estatisticamente significativa (p-valor  $\leq 5\%$ ).

# 3.1.4 Calibração e verificação do modelo

Uma vez definidos os parâmetros sensíveis para calibração, a próxima etapa é a calibração do modelo hidrológico. O período de calibração foi determinado para cada bacia de acordo com a disponibilidade de dados. A calibração do modelo hidrológico utilizando o algoritmo SUFI-2 é um processo iterativo que envolve, resumidamente, as seguintes etapas:

- i) Define-se um intervalo de valores para cada parâmetro;
- ii) É realizada uma amostragem de valores de todos os parâmetros, neste caso a amostragem foi realizada utilizando o Hipercubo Latino (MCKAY, 1992);
- iii) São realizadas simulações considerando n combinações de valores de parâmetros, sendo n o número de simulações definido pelo usuário;
- iv) É calculada a variância, o desvio padrão e o intervalo de confiança da função objetivo (a função objetivo é definida pelo usuário);
- v) Utilizando o melhor conjunto de parâmetros e o intervalo de confiança, é definido o novo intervalo de variação de cada parâmetro e a sensibilidade da rodada atual;
- vi) Uma nova rodada é executada utilizando o novo intervalo de valores de cada parâmetro, considerando apenas aqueles estatisticamente sensíveis.

Neste trabalho a função objetivo utilizada foi o coeficiente de Nash-Sutcliffe e foram realizadas 5 rodadas de 500 simulações (n = 500). O número de rodadas e de simulações foi definido de acordo com recomendações para calibração do modelo SWAT utilizando o algoritmo SUFI-2 (ABBASPOUR et al., 2007).

Na etapa de verificação, a melhor parametrização obtida na calibração é utilizada para um período diferente do período de calibração. A verificação tem como objetivo identificar se a parametrização obtida na calibração se mantém válida para um período fora do utilizado na calibração.

#### 3.1.5 Métricas de avaliação da calibração e verificação do modelo hidrológico

A avaliação da calibração e da verificação foi feita utilizando as métricas de Nash-Sutcliffe (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (EMA) e Erro Médio (EM), que são amplamente utilizadas para avaliação de desempenho de modelos hidrológicos (ALTHOFF; RODRIGUES, 2021).

O NSE (equação 2) é adimensional e pode assumir qualquer valor igual ou menor que 1. O NSE tende para 1 quanto melhor for o ajuste dos hidrogramas simulado e observado. O NSE compara o resíduo da vazão simulada com o resíduo da vazão média do período. Deste modo, valores negativos de NSE indicam que a vazão média representa melhor as vazões observadas do que a vazão simulada. O NSE utiliza o quadrado das diferenças no seu cálculo e, deste modo, há maior influência das vazões mais elevadas na determinação do coeficiente final em comparação com as vazões menores (LEGATES; MCCABE, 1999).

$$NSE = 1 - \frac{\sum_{t=1}^{n} (Q_{sim}(t) - Q_{obs}(t))^{2}}{\sum_{t=1}^{n} (\overline{Q_{obs}} - Q_{obs}(t))^{2}}$$
(Equação 2)

2

O KGE (equação 3) apresenta de forma explícita em sua formulação os mesmos componentes que estão implícitos no NSE. Sendo eles o coeficiente de correlação de Pearson (R), desvio padrão das simulações e observações ( $\sigma_{sim} \in \sigma_{obs}$ , respectivamente) e vazões médias simuladas e observadas ( $\overline{Q_{sim}} \in \overline{Q_{obs}}$ , respectivamente). Assim como o NSE, o KGE também é adimensional e pode assumir qualquer valor menor ou igual a 1 (GUPTA et al., 2009).

$$KGE = \sqrt{(R-1)^2 + \left(\frac{\sigma_{sim}}{\sigma_{obs}} - 1\right)^2 + \left(\frac{\overline{Q_{sim}}}{\overline{Q_{obs}}} - 1\right)^2}$$
(Equação 3)

O R (equação 4) mede o nível de relação linear entre as vazões simuladas e observadas. A correlação é adimensional e admite valores entre -1 e 1 para relações lineares perfeitamente negativas e positivas, respectivamente, e zero para nenhuma relação linear. A correlação é mais sensível a valores extremos e demonstra menos sensibilidade quando as discrepâncias são proporcionais (LEGATES; MCCABE, 1999).

$$R = \frac{\sum_{t=1}^{n} (Q_{obs}(t) - \overline{Q_{obs}}) (Q_{sim}(t) - \overline{Q_{sim}})}{\sqrt{\sum_{t=1}^{n} (Q_{obs}(t) - \overline{Q_{obs}})^{2} \cdot \sum_{t=1}^{n} (Q_{sim}(t) - \overline{Q_{sim}})^{2}}}$$
(Equação 4)

Uma das métricas mais utilizadas na avaliação de desempenho de modelos, o RMSE (equação 5) possui a mesma dimensão da variável avaliada, admite qualquer valor maior ou igual a zero, sendo que valores mais próximos de zero indicam melhor desempenho do modelo (ALTHOFF; RODRIGUES, 2021).

-

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^{n} (Q_{obs}(t) - Q_{sim}(t))^2}$$
(Equação 5)

O EMA (equação 6) pode assumir qualquer valor maior ou igual a zero e pode ser entendido como a magnitude média do erro entre as vazões observadas e simuladas. O RMSE pondera com mais peso os valores extremos enquanto que o EMA representa a magnitude média (ALTHOFF; RODRIGUES, 2021).

$$EMA = \frac{1}{n} \sum_{t=1}^{n} |Q_{obs}(t) - Q_{sim}(t)| \qquad (Equação 6)$$

O EM (equação 7) mede a tendência das simulações subestimarem ou superestimarem as vazões observadas (ALTHOFF; RODRIGUES, 2021).

$$EM = \frac{1}{n} \sum_{t=1}^{n} (Q_{obs}(t) - Q_{sim}(t))$$
(Equação 7)

## 3.2 Processamento das previsões numéricas de precipitação

O objetivo do processamento das previsões de precipitação é utilizar as observações de precipitação do local de interesse para adequar as previsões quantitativas de precipitação, considerando as características locais, corrigindo viés e melhorando o espalhamento dos membros do conjunto. Neste trabalho foram aplicadas metodologias para produzir previsões probabilísticas ajustando as previsões numéricas de precipitação às funções de distribuição de probabilidades (FDP's).

O período de análise foi definido de acordo com a disponibilidade de dias contínuos de previsões e observações de precipitação, que é um requisito para aplicação de técnicas de processamento das previsões. Foram avaliadas duas técnicas de processamento: *Bayesian Model Average* (BMA) com combinações de FDP do tipo Gama (SLOUGHTER et al., 2007; WILKS, 2011) e o método *Ensemble Model Output Statistics* utilizando os ajustes nas FDPs generalizada de valores extremos (GEV) e Gama deslocada e limitada para valores menores do que zero (*Censored and Shifted Gamma* – CSG) (SCHEUERER, 2014).

O modelo BMA produz previsões probabilísticas geradas a partir do ajuste de uma FDP às previsões numéricas de precipitação. A vantagem do modelo BMA está em combinar diferentes FDP's, ponderadas pelo peso de cada membro. Considerando M membros das previsões  $f_1 \dots f_M$  para uma precipitação x, em uma determinada localização espacial e temporal e admitindo que cada membro da previsão  $f_k$  tem uma distribuição condicional correspondente  $h_k(x|f_k; \theta_k)$  na qual  $\theta_k$  são os parâmetros a serem estimados, então o modelo BMA para previsão de x é (equação 8):

$$p(x|f_1 \dots f_M; \theta_1 \dots \theta_m) = \sum_{k=1}^M w_k h_k(x|f_k; \theta_k)$$
 (Equação 8)

Na qual  $w_k$  é o fator de ponderação dos modelos de cada um dos membros, baseado no desempenho da previsão  $f_k$  durante o período de treinamento, de modo que a soma dos fatores de ponderação é igual a 1 (equação 9).

$$\sum_{k=1}^{M} w_k = 1$$
 (Equação 9)

Para o caso das previsões de precipitação, é utilizada uma combinação entre uma componente discreta em 0 e as componente de distribuição de probabilidade são ajustadas em distribuições do tipo gama. Deste modo, o modelo BMA é dado da seguinte forma (equação 10):

$$p(x|f_1 \dots f_M; \theta_1 \dots \theta_m) = \sum_{k=1}^M w_k \{ p(X = 0|f_k) | I[x = 0] + p(X > 0|f_k) g_k(x|f_k) | I[x > 0] \}$$
(Equação 10)

No qual *I* é a função indicadora,  $g_k(x|f_k)$  é a distribuição gama com média e variância dadas respectivamente por  $\mu_k = b_{0k} + b_{1k} f_k^{\frac{1}{3}}$ ,  $\sigma_k^2 = c_0 + c_1 f_k$ , e a  $p(x = 0|f_k)$  é determinada da seguinte forma (equação 11):

$$logitP(x = 0|f_k) = log \frac{P(x = 0|f_k)}{P(x > 0|f_k)} = a_{ok} + a_{1k}f_k^{\frac{1}{3}} + a_{2k}\delta_k \quad (Equação 11)$$

Sendo que  $\delta_k = 1$ , se  $f_k = 0$  e  $\delta_k = 0$ , se  $f_k \neq 0$ . Os parâmetros  $a_{ok}$ ,  $a_{1k} e a_{2k}$  são estimados por regressão logística utilizando chuva/não-chuva como variável dependente e  $f_k^{\frac{1}{3}}$  e  $\delta_k$  como preditores. Já os parâmetros  $b_{ok}$  e  $b_{1k}$  são determinados para os casos em que há precipitação observada, por meio de regressão linear na qual a raiz cúbica da precipitação é a variável dependente e a raiz cúbica da previsão de precipitação é o preditor.

O ajuste de previsões de varáveis como temperatura e pressão ao nível médio do mar utilizando o modelo BMA é satisfatório supondo que estas variáveis se distribuem normalmente (RAFTERY et al., 2005). Contudo, o pressuposto de normalidade não é satisfatório para o caso da precipitação diária, cujo histograma apresenta como características o grande número de casos de precipitação zero e, nos casos de não zero, a distribuição é fortemente assimétrica (WILKS, 1990). Para contornar estas condições, o modelo BMA foi ajustado realizando a regressão logística (equação 11) com a raiz cúbica da precipitação como preditor (SLOUGHTER et al., 2007).

O processamento tanto utilizando a distribuição GEV, quanto utilizando a distribuição CSG, modelam a precipitação em uma única distribuição paramétrica. Para o caso da GEV, o modelo é limitado à esquerda em zero (equação 12) (SCHEUERER, 2014).

$$G(x) := \begin{cases} G(x) \text{ se } x \ge 0\\ 0 \text{ se } x < 0 \end{cases}$$
(Equação 12)

Na qual G(x) é a função de distribuição acumulada da distribuição GEV, que possui os parâmetros escala  $\mu$ , de forma  $\sigma$  e localização  $\xi$  (equação 13).

$$G(x) := \begin{cases} exp\left[-\left\{1 + \xi\left(\frac{x-\mu}{\sigma}\right)\right\}^{-\frac{1}{\xi}}\right] se \ \xi \neq 0\\ exp\left[-exp\left(\frac{x-\mu}{\sigma}\right)\right] \quad se \ \xi = 0 \end{cases}$$
(Equação 13)

No caso da distribuição CSG, a distribuição gama possui, além dos parâmetros de forma ( $\kappa$ ) e de escala ( $\theta$ ), um parâmetro de deslocamento ( $\delta$ ). A limitação do modelo CSG transforma a probabilidade de valores menores que zero da distribuição gama sem limitação em probabilidade de zero, substituindo todos os valores negativos por zero. O parâmetro de deslocamento permite mover a distribuição para a esquerda em relação à distribuição gama com dois parâmetros (SCHEUERER; HAMILL, 2015).

Neste trabalho a definição da janela móvel ideal foi feita a avaliando o gráfico do *Continuous Ranked Probability Score* médio ( $\overline{CRPS}$ ) utilizando diferentes janelas de dias antecedentes ao dia de previsão (JAVANSHIRI; FATHI; MOHAMMADI, 2021) para a chuva média diária observada nas bacias de interesse. Neste método, diferentes janelas são testadas e plotado um gráfico do  $\overline{CRPS}$  em função do tamanho da janela de treinamento. O próximo item deste capítulo apresenta mais detalhes a respeito do  $\overline{CRPS}$ .

A figura 2 ilustra o resultado de variação do  $\overline{CRPS}$  em função do tamanho da janela de treinamento para o processamento de previsões quantitativas de precipitação com 24 h de antecipação utilizando BMA (JAVANSHIRI; FATHI; MOHAMMADI, 2021). O resultado da previsão é melhor quanto mais próximo de zero for o valor do  $\overline{CRPS}$ . Observa-se que, à medida que o tamanho da janela aumenta, o  $\overline{CRPS}$  diminui até próximo de 80 dias, quando o coeficiente passa a apresentar estabilidade. Neste exemplo os autores adotaram a janela de 87 dias para o processamento, porém, a variação é pequena para janelas de tamanho maior que 85 dias. Deste modo, em termos de desempenho do  $\overline{CRPS}$ , seria satisfatória a escolha de qualquer janela com tamanho maior do que 85 dias.



Figura 2 - Exemplo de resultado do CRPS para definição da janela de treinamento, neste caso os autores definiram a

Fonte: Adaptado de Javanshiri; Fathi; Mohammadi (2021)

O processamento realizado transforma a previsão por conjunto, que é uma previsão discreta composta por 51 membros, em uma FDP contínua. Deste modo, a entrada das previsões processadas no modelo hidrológico será feita utilizando os quantis de probabilidade de excedência da precipitação de 5% a 95% com passo de 10%, gerando assim 10 entradas ("membros" oriundos dos modelos probabilísticos) para cada passo temporal de previsão.

Para alimentar o modelo hidrológico, o processamento foi realizado em cada uma das minibacias do modelo. Sendo que a chuva observada e as previsões brutas foram interpolada para o centroides das minibacias e o processamento foi realizado utilizando a chuva observada e a previsão bruta do centroide.

#### 3.3 Experimentos de previsão de vazão

Para a realização das previsões de cheia o modelo hidrológico foi alimentado com o conjunto de previsões quantitativas de precipitação. Cada membro do conjunto de previsão de precipitação será utilizado para geração de uma previsão de vazão. A precipitação entra no SWAT pontualmente e para alimentação (forçamento) do modelo hidrológico foi considerado o ponto correspondente ao centroide da minibacia. Foram realizadas previsões hidrológicas de 24 h com antecipação de até 120 horas. A seguir é feito o detalhamento do esquema de forçamento com as previsões quantitativas de precipitação do ECMWF e com as previsões geradas pelos modelos probabilísticos.

O esquema geral para alimentar o modelo hidrológico nos experimentos de previsão hidrológica utilizando as previsões quantitativas de precipitação do ECMWF é mostrado na figura 3. Sendo  $T_{i1}$  o tempo de início da previsão para a primeira rodada de previsão e  $T_{f1}$  o tempo final da primeira rodada de previsão,  $T_{i2}$  o tempo de início da previsão para a segunda rodada de previsão e  $T_{f2}$  o tempo final da segunda rodada de previsão.



Figura 3 - Esquema de alimentação do modelo hidrológico utilizando previsões quantitativas de precipitação do

Previsões quantitativas de precipitação do ECMWF (51 membros)



Previsões quantitativas de precipitação do ECMWF (51 membros)

Fonte: Elaborado pelo autor.

Para o caso das previsões de precipitação processadas com os modelos probabilísticos a metodologia é semelhante (figura 4). Contudo, destaca-se que os pares chuva observada e previsão quantitativa de precipitação do ECMWF do período referente à janela de treinamento (J) é utilizado para determinar a distribuição de probabilidade que será utilizada.

Em seguida, valores discretos das previsões probabilísticas contínuas foram extraídos utilizando os quantis probabilísticos de 5% a 95% ( $P(p \ge 0.05)$ ) até  $P(p \ge 0.95)$ ) em intervalos de 10%, gerando assim um "conjunto" de 10 membros para as previsões probabilísticas. Destaca-se que neste caso os membros não são equiprováveis e para a saída de vazão foi adotada a mesma

probabilidade do quantil de precipitação. Ou seja, a precipitação associada ao quantil de 5% de probabilidade de excedência gera uma previsão de vazão com probabilidade de excedência de 5%.





Fonte: Elaborado pelo autor.

# 3.3.1 Ajuste da vazão prevista

A figura 5 ilustra casos hipotéticos em que a vazão simulada pelo modelo é subestimada (figura 5a) e superestimada (figura 5b). Em ambos os casos a diferença entre simulado e observado compromete a qualidade da previsão de vazão, pois, ainda que a previsão quantitativa de precipitação fosse perfeita o ponto de início da previsão já apresenta diferença em relação à vazão real. De outro modo, mesmo que a previsão fosse perfeita (igual à precipitação observada), o resultado da vazão simulada pelo modelo hidrológico não iria corresponder precisamente à vazão observada.

Figura 5 – Hidrograma observado e simulado, na figura (a) a vazão simulada é subestimada pelo modelo enquanto que em (b) as vazões simuladas são superestimadas.



Fonte: Elaborado pelo autor.

Durante a realização dos experimentos de previsão de vazão, observou-se que o modelo hidrológico é sensível às variações promovidas pelas previsões quantitativas de precipitação. Deste modo, para contornar problemas de diferença na vazão simulada e observada no início da previsão, foi aplicada uma correção das vazões previstas.

O objetivo da correção proposta é utilizar a tendência indicada pela previsão de vazão, aplicando na melhor condição inicial disponível para realizar a previsão. O esquema proposto será ilustrado para o primeiro horizonte de previsão, cujo ajuste é feito conforme a equação 14:

$$Q(24h)_{aju}^{m} = \frac{Q(24h)_{prev}^{m}}{Q(0h)_{sim}} Q(0h)_{obs}$$
(Equação 14)

No qual  $Q(24h)_{aju}^{m}$  é a previsão ajustada para o horizonte de 24 h no membro m,  $Q(24h)_{prev}^{m}$  é a previsão alimentando o modelo hidrológico com previsões quantitativas de precipitação do membro m para o horizonte de 24 h,  $Q(0h)_{sim}$  é a vazão simulada no início da previsão (última vazão simulada com o modelo hidrológico alimentado com chuva observada)  $Q(0h)_{obs}$  é a vazão observada no inicio da previsão (ou seja, é a última observação disponível antes de iniciar a previsão).

Deste modo, o que está sendo feito é utilizar a tendência linear indicada pela previsão de vazão para 24 horas na última vazão observada (que neste caso representa a melhor condição inicial disponível). Para os demais horizontes de tempo, será considerado que a melhor condição inicial é a previsão anterior ajustada e a equação 14 pode ser generalizada para os demais horizontes de tempo da seguinte forma (equação 15):

$$Q(h)_{aju}^{m} = \frac{Q(h)_{prev}^{m}}{Q(h-1)_{prev}^{m}} Q(h-1)_{aju}^{m}$$
(Equação 15)

No qual  $Q(h)_{aju}^{m}$  é a previsão do membro m para o horizonte h ajustada,  $Q(h)_{prev}^{m}$  é a previsão para o horizonte de previsão h realizada alimentando o modelo hidrológico com previsões quantitativas de precipitação do membro m para o horizonte h,  $Q(h-1)_{prev}^{m}$  é a previsão para o horizonte h-1 realizada alimentando o modelo hidrológico com previsões quantitativas de precipitação para o horizonte de previsão h-1 e  $Q(h-1)_{aju}^{m}$  é a vazão prevista ajustada no passo anterior para o horizonte de previsão h-1.

#### 3.4 Métricas de avaliação das previsões de precipitação e de vazão

Para avaliar as previsões de precipitação foram utilizadas métricas determinísticas, nas quais a previsão por conjunto é reduzida a uma previsão determinística, e métricas que consideram a distribuição dos conjuntos. Para o conjunto de previsões brutas do ECMWF foi utilizada a média dos membros como previsão determinística e para as previsões processadas, foi considerado o quantil de superação de 50% como medida central e referência para previsão determinística.

As métricas utilizadas tanto para avaliação das previsões de precipitação quanto para a previsão de vazão, foram selecionadas de modo a descrever diferentes características de comportamento das previsões (FAN, 2015):

- Coeficiente de correlação (R);
- Erro médio absoluto (EMA);
- Erro médio (EM);
- Brier Score (BS);
- Continous Ranked Probability Score médio (CRPS)
- *Relative Operating Characteristic* (curva ROC)
- Reliability Diagram (Diagrama de Confiabilidade);
- Rank Histogram
- Probability Integral Transform Histogram (PIT)

O *BS* é a primeira métrica da lista que avalia a previsão por conjunto. Essa métrica é equivalente ao erro quadrático médio para previsões por conjunto, considerando eventos dicotômicos (ocorrência ou não do evento), de acordo com a equação 16.

$$BS = \frac{1}{n} \sum_{k=1}^{n} (y_k - o_k)^2$$
 (Equação 16)

No qual,  $y_k$  é a probabilidade de previsão,  $o_k$  é a observação do evento e assume valor 1 quando o evento ocorre e 0 quando o evento não ocorre.

A ocorrência ou não de evento pode ser definida, por exemplo, pela ocorrência ou não de precipitação em um dia, ou a superação ou não de um limiar previamente estabelecido. O *BS* possui orientação negativa de modo que valores próximos de zero indicam pouca diferença entre a probabilidade de previsão e a probabilidade de ocorrência do evento.

O *CRPS* (equação 17) é utilizado para avaliar previsões probabilísticas contínuas, comparando a diferença quadrática das integrais das funções de probabilidade acumulada das previsões e das observações.

$$CRPS = \int_{-\infty}^{\infty} [F(y) - F_o(y)]^2 dy \qquad (Equação 17)$$

Na qual F(y) é a função de probabilidade acumulada para previsão e  $F_o(y)$  é a função de probabilidade acumulada para observação, que é uma função de *Heaviside* definida da seguinte forma (equação 18):

$$F_o(y) := \begin{cases} 0, se \ y < valor \ observado \\ 1, se \ y \ge valor \ observado \end{cases}$$
(Equação 18)

O *CRPS* também possui orientação negativa, uma vez que valores baixos de *CRPS* indicam que a diferença entre as funções de probabilidade acumulada é pequena. Isoladamente o valor de *CRPS* para uma determinada previsão não expressa a qualidade da previsão, contudo, o *CRPS* pode ser usado como uma métrica de comparação entre previsões. O  $\overline{CRPS}$  é calculado aplicando o *CRPS* para todos os *n* pares observação e previsão (equação 19).

$$\overline{CRPS} = \frac{1}{n} \sum_{i=1}^{n} CRPS_i = \frac{1}{n} \sum_{i=1}^{n} \left[ \int_{-\infty}^{\infty} [F(y) - F_o(y)]^2 dy \right]_i \quad \text{(Equação 19)}$$

A curva ROC (figura 6) fornece uma medida da confiabilidade da previsão, avaliando se o limiar utilizado (*cutoff*) para definir a previsão ou não de um evento (neste caso, o limiar se refere ao percentil dos membros do conjunto que indicam chuva acima de um determinado valor) é determinante para a detecção do evento. Em uma previsão perfeita, a detecção independe do percentil do conjunto e a área abaixo da curva ROC é igual a 1. Para a previsão bruta do ECMWF foi utilizado os percentis de 5%, 15%, 25%, 35%, 45% 55%, 65%, 75%, 85% e 95% como referência de limiar de previsão. Para os casos dos modelos ajustados, foram utilizadas as mesmas classes, porém, por se tratarem de distribuições contínuas de probabilidades, as classes foram usadas para definição dos limiares quantílicos das distribuições de probabilidade.



O diagrama de confiabilidade mostra a distribuição completa de previsões e observações para previsões probabilísticas de um preditando binário (WILKS, 2011). Neste caso, o preditando binário é a excedência de um determinado limiar de chuva.

O diagrama de confiabilidade é composto por dois elementos, a curva de calibração e o gráfico de refinamento da distribuição. A curva de calibração dispõe no eixo X as probabilidades de previsão de um evento maior ou igual ao limiar estabelecido e no eixo Y é a probabilidade condicional de observação do evento, dada uma probabilidade de previsão, ou seja, o eixo Y apresenta a frequência real de ocorrência dos eventos dentro de uma probabilidade de previsão ou dentro de um intervalo de probabilidade de previsão. Em um sistema de previsão perfeito, a probabilidade de previsão deve ser igual à frequência de observações, sendo assim, a curva de calibração ideal é representada por uma reta 1:1.

A figura 7 mostra exemplos de gráficos de funções de calibração. No gráfico da parte superior da figura, é mostrado um caso no qual a frequência de observação é menor do que a respectiva probabilidade de previsão, ou seja, a previsão está superestimando as ocorrências.

Fonte: adaptado de Wilks (2011)

O caso oposto é apresentado no gráfico inferior. Neste exemplo a frequência de observações é maior que a sua probabilidade de previsão e então as previsões estão subestimando a real frequência de ocorrência dos eventos.

O gráfico da direita apresenta o caso em que a frequência de observações tem relação fraca com a probabilidade de previsão e climatologia pondera a probabilidade condicional de observação (a frequência relativa climatológica está localizada próxima do centro com os pontos alinhados verticalmente).

Por fim, o gráfico da esquerda exibe um caso em que a probabilidade condicional de observação é subestimada (superestimada) para previsões com baixa (alta) frequência relativa. Neste caso as previsões são capazes de identificar subconjuntos de previsão em que os resultados são diferentes uns dos outros. Por exemplo, probabilidades de previsão pequenas, mas diferentes de zero, identificam um subconjunto de previsão no qual o evento não ocorre.

Figura 7 - Exemplos de curvas de distribuição com suas respectivas avaliações de acordo com a forma da curva. A linha tracejada indica o limiar de uniformidade que é dado pela reta 1:1, no eixo X são indicadas as probabilidades de previsões e no eixo Y é indicada a frequência condicional de observação de um evento dada a sua probabilidade de



previsão

Fonte: Adaptado de (WILKS, 2011)

O gráfico de refinamento da distribuição representa a dispersão das previsões. Quando as previsões dificilmente se alteram, ou seja, estão sempre próximas do seu valor médio, há pouca confiança. Por outro lado, as previsões que são extremas, ou seja, são previsões que indicam probabilidades próximas aos valores de certeza (probabilidade de previsão zero ou um) possuem confiança alta.





Fonte: Adaptado de (WILKS, 2011)

O *rank histogram* avalia a dispersão dos membros do conjunto de previsões. Um bom conjunto de previsões deve apresentar um histograma uniforme, conforme mostrado na figura 9. Para o caso das previsões processadas ajustadas a FDPs, o PIT (*Probability Integral Transform rank*) é utilizado para avaliar a dispersão das previsões probabilísticas através de histogramas que são interpretados da mesma maneira que o *rank histogram*.

Figura 9 - Exemplos de rank histograms com suas respectivas avaliações de acordo com a forma do histograma. A linha tracejada indica o limiar de uniformidade que é dado por (N<sub>classes</sub>)<sup>-1</sup>, no eixo X são indicadas as posições que uma observação pode ocupar (as posições podem ser intervalos de valores entre os membros ou no limite pode haver uma posição para cada membro) e no eixo Y é indicada a frequência com que as observações ocuparam uma



Fonte: adaptado de Wilks (2011)

# 4 PREVISÕES HIDROLÓGICAS PARA BACIA HIDROGRÁFICA DO RIO PARAÍBA DO SUL

Este capítulo apresenta a aplicação da metodologia proposta para a bacia hidrográfica do rio Paraíba do Sul (BHPS). Inicialmente, são apresentadas as características físicas da bacia, seguido pelos resultados da modelagem hidrológica, incluindo o pré-processamento do modelo hidrológico, análise de sensibilidade, da calibração e da verificação do modelo, posteriormente é apresentada a avaliação da previsão de chuva para bacia, os resultados da previsão de vazão para os postos fluviométricos da bacia e por fim a conclusão do capítulo.

# 4.1 Características da BHPS

O Rio Paraíba do Sul é formado pela confluência dos rios Paraitinga e Paraibuna no Estado de São Paulo e percorre cerca de 1.130 km até sua foz no Oceano Atlântico, em São João da Barra no Estado do Rio de Janeiro. A área de drenagem da BHPS definida neste trabalho (figura 10) possui 16.630 km<sup>2</sup> e corresponde ao trecho desde as nascentes dos rios Paraíba do Sul até a barragem da Elevatória Santa Cecília, onde parte da vazão do rio Paraíba do Sul é transposta para geração de energia e abastecimento da região metropolitana do Rio de Janeiro.

A área de drenagem da BHPS possui população aproximada de 4.3 milhões de habitantes, cobre total ou parcialmente 69 municípios, dos quais 48 pertencentes ao estado de São Paulo, 12 ao estado do Rio de Janeiro e 8 ao estado de Minas Gerais.

A BHPS está situada em uma região de relevo acidentado, sendo limitada a noroeste pela Serra da Mantiqueira, que separa a bacia do Paraíba do Sul das bacias dos rios Grande e Doce; e a sudeste pela Serra do Mar, que separa a bacia do Paraíba do Sul da bacia litorânea de rios litorâneos que desaguam no Oceano Atlântico.



Figura 10 - Localização bacia hidrográfica do Rio Paraíba do Sul (BHPS)

Fonte: Elaborado pelo autor. Limites de bacia e hidrografia (ANA, 2012) e divisões políticas (IBGE, 2020)

De acordo com o levantamento do Mapbiomas (figura 11), a cobertura da superfície na BHPS é composta majoritariamente por pastagem (37%) e formação florestal (34%). Outros usos expressivos da bacia são identificados como floresta plantada (4%), infraestrutura urbana (4%) e corpos d'água (2%). A distribuição da cobertura da bacia é homogênea com mancha de infraestrutura urbana ao longo das margens do rio Paraíba do Sul (figura 11).



Figura 11 – Cobertura da superfície da Bacia Hidrográfica do Rio Paraíba do Sul (BHPS)

Fonte: Elaborado pelo autor com informações de uso e cobertura da superfície do Projeto Mapbiomas (2020)

A BHPS possui reservatórios para abastecimento de água e geração de energia elétrica (tabela 4). O primeiro reservatório, Paraibuna, ocorre na confluência dos rios Paraitinga e Paraibuna, a cerca de 100 km a jusante da nascente do rio Paraitinga e tem como finalidade a geração de energia elétrica. O rio Jaguari, afluente do rio Paraíba do Sul pela margem direita, possui reservatório para geração de energia elétrica e, mais recentemente, para abastecimento público através do vertimento de suas águas para o sistema Cantareira.

Nome	$\Delta D (km^2)$	$\Delta I (Km^2)$	Volume	Nível	Nível	Finalidade
Nome	AD (KIII)	AI (KIII )	útil (hm³)	Máximo	Mínimo	Principal
Paraibuna	4094	177	2,63	714	696	Hidrelétrica
Santa Branca	5030 <sup>1</sup>	27 <sup>2</sup>	308 <sup>1</sup>	622 <sup>1</sup>	605 <sup>1</sup>	Hidrelétrica
Jaguari	1300 <sup>1</sup>	56 <sup>3</sup>	793 <sup>1</sup>	623 <sup>1</sup>	603,2 <sup>1</sup>	Hidrelétrica/ Abastecimento
Funil	$15480^{1}$	$40^{1}$	$6200^{1}$	$468^{1}$	$444^{1}$	Hidrelétrica

Tabela 4 – Características dos principais reservatórios existentes na bacia, onde AD se refere à área de drenagem a montante do reservatório e AI à área inundada pelo reservatório.

Fonte: <sup>1</sup>ONS (2017), <sup>2</sup>Light (2016), <sup>3</sup>CESP (2014)

O regime hidrológico da bacia é caracterizado por verões úmidos e invernos secos, com ano hidrológico (AH) definido de outubro a setembro. O regime de chuvas é influenciado principalmente pela Zona de Convergência do Atlântico Sul, sendo importantes também a entrada de sistemas frontais e a brisa marítima (JORGETTI; DA SILVA DIAS; DE FREITAS, 2014). Em janeiro ocorre o maior acumulado de precipitação e maior vazão média mensal, porém, não corresponde necessariamente ao mês da máxima precipitação diária anual ou da vazão máxima diária anual (Figura 12).



Figura 12 – Modelo Digital de Elevação da Bacia Hidrográfica do Paraíba do Sul, postos fluviométricos utilizados e gráficos chuva-vazão ilustrativo do comportamento hidrológico da bacia.

Fonte: Elaborado pelo autor. Modelo digital de elevação SRTM (NASA, 2013), dados vazão natural disponíveis em ANA (2020), vazão medida em ANA (2021) e dados de precipitação disponibilizados por Beck et al. (2019).

A tabela 5 apresenta estatísticas descritivas dos postos de vazão existentes na bacia que auxiliam na interpretação das características do regime hidrológico da bacia, mais detalhes a respeito do cálculo destas estatísticas podem ser obtidos em Naghettini e Pinto (2007).

A razão Q10%/Q50% mostra que as vazões de cheia são entre 2 e 2.7 vezes maior que a mediana, os coeficientes de assimetria (S) e curtose (K) mostram que o histograma de frequências possui desvio positivo e distribuição leptocúrtica ("pontiaguda"). Em conjunto estes parâmetros mostram que a BHPS possui regime de vazão responde de forma rápida e acentuada à precipitação. Bacias com estas características, quando comparadas com bacias de respostas gradual lenta, apresentam um desafio maior para previsão hidrológica de inundações de curto prazo.

Tabela 5 – Estatísticas descritivas do regime de vazão dos postos de monitoramento: vazão média ( $\overline{\mathbf{Q}}$ ), desvio padrão (SD), coeficiente de variação, vazão com permanência de superação de 10%, e 95% (Q10% e Q95%, respectivamente), razão entre Q10% e Q50%, vazão máxima diária anual média (MDM), assimetria (S) e curtose (K).

Posto	$\overline{\mathbf{Q}}$	SD	CV	Q10%	Q95%	Q10%/Q50%	S	K	MDM
Cunha	13,8	9,1	1,0	25,2	5,3	2,3	2,2	6,5	56,9
São Luís do Paraitinga	27,9	20,6	1,4	53,0	10,6	2,5	2,6	9,1	132,7
Ponte Alta I	7,6	8,6	1,4	12,6	3,2	2,1	28,6	1358,4	81,7
Jaguari	23,8	19,0	1,0	45,2	7,7	2,4	3,3	17,4	141,7
Santa Branca	73,4	53,7	1,0	136,7	26,3	2,4	3,7	32,3	341,9
Santa Cecília	256,1	193,9	1,1	505,6	83,7	2,7	2,1	5,4	1027,0
	1								

Fonte: Elaborado pelo autor.

#### 4.2 Pré-processamento do modelo hidrológico

O modelo SWAT foi aplicado para a BHPS no período de 01/01/2005 a 31/12/2020. O período de 01/01/2005 até 31/12/2011 foi utilizado para a calibração do modelo e o restante do período (01/01/2012 a 30/12/2020) foi utilizado para a validação do modelo e posteriormente para a realização dos experimentos de previsão de vazão.

A figura 13 apresenta o resultado da geração das 123 minibacias e da rede de drenagem com o SWAT, localização espacial dos centros da grade de reanálise de vento, radiação, umidade, localização espacial dos centros da grade de chuva do MSWEP e localização dos centroides das previsões numéricas de precipitação do ECMWF.

O SWAT resolve a precipitação na minibacia pelo método do vizinho mais próximo. Uma vez que a interpolação pelo inverso da distância tem se mostrado mais eficiente na representação do campo de precipitação em modelagem com o SWAT (SZCZEŚNIAK; PINIEWSKI, 2015), os dados de precipitação do MSWEP foram previamente interpolados para os centroides das minibacias.

Figura 13- Divisão em minibacias e representação da (a) centroides das minibacias, (b) centroides da grade reanálise, (c) rede de drenagem do SWAT, (d) centroides da grade de chuva observada e (e) centroides das previsões numéricas de chuva do ECMWF



Fonte: Elaborado pelo autor.

Durante o pré-processamento também é feita a delimitação das URHs da bacia. No SWAT as URHs são definidas pelo cruzamento de informações de cobertura da superfície, tipo de solo e relevo (figura 14). Neste trabalho foram utilizadas as informações de cobertura da superfície do Mapbiomas, sendo que as classes semelhantes foram agrupadas em uma mesma classe, conforme a tabela 6.

Classe Mapbiomas	Classe SWAT
Formação florestal	FRSE
Floresta plantada	FRSE
Campo alagado	FRSE
Formação campestre	FRSE
Pastagem	PAST
Mosaico agricultura e pastagem	PAST
Infraestrutura Urbana	URHD
Outras	PAST
Corpo d'água	WATER
Soja	PAST
Outras culturas	PAST

Tabela 6 – Reclassificação das classes de cobertura da superfície do Mapbiomas para as classes do banco de dados do SWAT

Fonte: Elaborado pelo autor.

A tabela 7 apresenta os valores iniciais dos parâmetros de superfície que são relevantes para a geração de escoamento superficial. Para o caso dos usos denominados FRSE (floresta sempre verde) e PAST (áreas agrícolas) estes parâmetros se referem ao coeficiente de Manning para escoamento superficial (OV\_N) e o valor da curva número do SCS para condição de umidade II (CN2). Para o caso do uso denominado URHD (urbano de alta densidade), além dos parâmetros anteriores, inclui-se o valor da curva número do SCS para condição de umidade II em área urbana (URBCN2), fração da área urbana impermeável (FIMP) e a fração da área urbana impermeável interconectada (FCIMP).
Cabantana	OV N		CN	2							IA	F					
Cobertura	UV_N	Α	В	С	D	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
FRSE	0.10	25	55	70	77	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0
PAST	0.15	49	69	79	84	3.0	3.0	2.0	2.0	1.5	1.5	1.5	1.5	2.0	2.0	2.0	3.0
		OV	N					SCS I	Runof	ff Cur	ve N	umb	ers				
		0.	_1N		Α				]	B			С		D	)	
URHD		0.1	[		31				5	9			72		79	)	
		URBO	CN2	FI	MP (fr	action	I)	FC	IMP	(fracti	ion)						
		98	5		0.6	5			0.	44							

Tabela 7 - Valores iniciais dos parâmetros de superfície relevantes para geração de escoamento

Fonte: elaborado pelo autor

A tabela 8 apresenta os valores dos parâmetros de solo relevantes para geração de escoamento no modelo SWAT e adotados para iniciar a modelagem da bacia do rio Paraíba do Sul.

		Latagola	Argiccolo	Cambiggala
Parâmetro	Camada	(LVAd)	(PVAd)	(CXbd)
NLAYERS		4	6	6
HYDGRP		А	С	В
SOL_ZMX		1400	1200	1000
SOL_Z1		200	200	200
SOL_AWC1	1	0.23	0.19	0.24
SOL_K1		75	65	45
SOL_Z2		1400	1200	700
SOL_AWC2	2	0.27	0.28	0.27
SOL_K2		33	21	20
SOL_Z3		1210	1000	1000
SOL_AWC3	3	0.4	135	135
SOL_K3		12.5	1	1
SOL_Z4		1500	1300	1300
SOL_BD4		1.6	1.35	1.35
SOL_AWC4	- 4 -	0.4	0.21	0.21
SOL_K4		12.5	0.7	0.7
SOL_Z5		-	1600	1600
SOL_AWC5	5	-	0.14	0.14
SOL_K5		-	8	8
SOL_Z6		-	2200	2200
SOL_AWC6	6	-	0.15	0.15
SOL K6		-	0.5	0.5

Tabela 8 - Valores iniciais dos parâmetros de solo para geração de escoamento

O relevo foi subdividido em duas classes: acima de 5% de declividade e abaixo de 5% de declividade. Esta subdivisão foi feita para permitir que o modelo aceite valores de CN diferentes para um mesmo tipo de cobertura e solo com declividade diferente. Este ajuste é necessário uma vez que os valores de CN da base de dados do SWAT consideram declividade de até 5% (NIETSCH et al., 2009).

Figura 14 – Classes de (a) tipo de cobertura, (b) solos e (c) declividade utilizada para cruzamento e geração das unidades de resposta hidrológica.



Fonte: Elaborado pelo autor.

Por fim, as classes de cobertura, tipo de solo e relevo que representam menos de 10% da área de uma minibacia é incorporada à classe mais próxima da mesma minibacia. A figura 15 apresenta as classes de cobertura da superfície, classes de solo, classes de declividade do relevo e o resultado do cruzamento dessas informações que resultam em 18 URHs.



Figura 15 - Unidades de resposta hidrológica na bacia do Rio Paraíba do Sul

Fonte: Elaborado pelo autor.

# 4.3 Análise de sensibilidade, calibração e validação do modelo hidrológico para Bacia do Rio Paraíba do Sul

Após o pré-processamento foi realizada a análise de sensibilidade do modelo hidrológico para a bacia conforme descrito no item 3.1.3. A tabela 9 mostra o resultado do teste-t e o p-valor para os 20 parâmetros considerados na análise de sensibilidade. Em negrito, estão destacados os parâmetros cuja sensibilidade é estatisticamente significativa, sendo eles o CN2 (curva número do SCS para condição de umidade II), SURLAG (coeficiente de delay no escoamento superficial), LAT\_TIME (tempo de viagem no escoamento lateral), CANMX (armazenamento máximo no dossel), OV\_N (coeficiente de Manning para escoamento em área inundada), ESCO (fator de compensação da evaporação do solo) e SOL\_AWC (capacidade de armazenamento de água na camada de solo).

O CN2 influencia diretamente na separação do escoamento superficial do subsuperficial, o SURLAG tem impacto mais direto na forma do hidrograma, na vazão máxima de pico e no tempo de ocorrência da máxima, o LAT\_TIME tem influencia na vazão de base e o OV\_N impacta na velocidade de propagação da água durante cheias. Os demais coeficientes possuem influencia indireta na vazão gerada, o SOL\_AWC controla a capacidade de armazenamento de água no solo, que por sua vez interage com

o CN2 via umidade do solo para determinar o escoamento superficial, o ESCO controla a quantidade de água do solo que vai evaporar e consequentemente também influencia na umidade do solo e no CN2 e o CANMX vai determinar o volume de água que vai atingir a superfície e que poderá escoar superficialmente ou infiltrar no solo.

Tabela 9 – Resultado da análise de sensibilidade dos parâmetros importantes para representação da vazão na bacia do rio Paraíba do Sul. Em negrito estão destacados os parâmetros cuja sensibilidade é estatisticamente significativa (p-valor < 5%)

Parâmetro	teste-t	p-valor
CN2.mgt	-30.5	<0.01%
SURLAG.hru	-10.7	<0.01%
LAT_TTIME.hru	7.0	<0.01%
CANMX.hru	4.2	<0.01%
OV_N.hru	3.8	<0.01%
ESCO.hru	2.2	2.6%
SOL_AWC.sol	-2.1	3.2%
SLSUBBSN.hru	-1.3	18.9%
SOL_K.sol	-1.1	26.9%
CH_K2.rte	0.9	38.6%
EPCO.bsn	0.7	49.7%
GWQMN.gw	0.5	64.4%
CH_N2.rte	0.4	66.4%
GW_DELAY.gw	0.4	68.3%
ALPHA_BF.gw	0.4	68.8%
SURLAG.bsn	-0.3	76.0%
GW_REVAP.gw	0.2	80.8%
REVAPMN.gw	0.1	91.2%
ALPHA_BNK.rte	-0.1	93.1%
RCHRG_DP.gw	-0.1	95.8%

Fonte: Elaborado pelo autor.

Deste modo, a calibração do modelo foi iniciada considerando apenas os parâmetros cuja sensibilidade possui significância estatística e utilizando o intervalo de valores proposto para a análise de sensibilidade (Tabela 10).

Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo
CANMX.hru	Valor	0	100
CN2.mgt	Relativa	-0.9	0.9
ESCO.hru	Valor	0.01	1
SOL_AWC.sol	Relativa	-0.9	0.9
SURLAG.bsn	Valor	0.1	24
OV_N.hru	Valor	0.01	30
LAT_TTIME.hru	Valor	0	10

Tabela 10 – Parâmetros utilizados para iniciar e calibração do modelo. Para o tipo de mudança Valor, o valor inicial é substituído por valores dentro do intervalo especificado e para mudança relativa o valor inicial é multiplicado por 1+ r, em que r é um valor no intervalo especificado

Fonte: Elaborado pelo autor.

A seleção do melhor conjunto de parâmetros foi feita considerando o melhor resultado da média da função objetivo em todos os pontos em que há observação disponível. Será mostrado neste capítulo apenas o resultado final dos melhores parâmetros, uma análise detalhada dos resultados em cada uma das rodadas de calibração é mostrada no anexo C.

Na tabela 11 são mostrados os valores dos coeficientes de Nash, Kling-Gupta, Correlação, Raiz do Erro Quadrático Médio, Erro Médio Absoluto e Erro Médio para o período de calibração do modelo. O posto Santa Cecília apresentou o melhor desempenho no período de calibração, enquanto que o posto Cunha obteve o pior desempenho.

Tabela 11 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE) e Erro Médio Absoluto (EMA) para o período de calibração (01/01/2005 até 31/12/2011)

Posto	NSE	KGE	R	RMSE	EMA	EM
Santa Cecília	0,78	0,75	0,94	103,68	86,92	-44,96
Estrada do Cunha	-0,07	0,43	0,76	9,94	7,91	-3,92
São Luis do Paraitinga	0,24	0,5	0,82	20,07	14,37	0,56
Ponte Alta I	0,36	0,55	0,62	9,4	3,83	-0,88
Santa Branca	0,52	0,66	0,85	42,99	33,04	-3,09

Fonte: Elaborado pelo autor.

Os mesmos coeficientes para o período de validação são mostrados na tabela 12. A respeito dos resultados apresentados da calibração e validação do modelo hidrológico, conclui-se que o modelo apresenta dificuldade para representação do período seco, subestimando das vazões nesse período. O resultado tanto da calibração quanto da validação foi melhor para as estações com maior área de drenagem, o que pode ser resultado das limitações que o SWAT apresenta no seu método de propagação de vazão e do tempo de concentração mais curto das bacias menores. Outro ponto importante que deve ser evidenciado a respeito da limitação nas estações com menor área de drenagem é que o produto de precipitação utilizado pode ter dificuldades em capturar eventos de chuva localizados na área a montante dos postos em área de drenagem menor e que ocasionam variação de vazão nos postos. Apesar das limitações apresentadas o resultado da simulação com SWAT para o período de calibração e validação pode ser considerado aceitável, principalmente para os postos Santa Branca e Santa Cecília. O anexo C apresenta os gráficos de dispersão e os hidrogramas simulado e observado de cada uma das estações

Tabela 12 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R2), Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (EMA) e Erro Médio (EM) para o período de validação

Posto	NSE	KGE	R	RMSE	EMA	EM
Santa Cecília	0,59	0,67	0,88	105,08	85,56	-68,7
Estrada do Cunha	0,19	0,58	0,74	7,00	5,51	-3,44
São Luís do Paraitinga	0,38	0,65	0,79	13,53	10,52	-5,3
Ponte Alta I	-0,06	0,43	0,59	5,00	3,41	-2,62
Santa Branca	0,40	0,63	0,82	32,77	26,09	-12,92

Fonte: Elaborado pelo autor.

## 4.4 Previsões numéricas de precipitação

Este item trata da avaliação das previsões de precipitação da BHPS. É apresentada tanto a avaliação das previsões quantitativas de precipitação do ECMWF (denominada de previsões brutas do ECMWF) quanto à avaliação das previsões processadas para geração de previsões probabilísticas. O item apresenta primeiramente o resultado da definição da janela de processamento, seguida por uma avaliação comparativa entre as previsões brutas do ECMWF e as previsões processadas utilizando os modelos BMA, GEV e CSG.

### 4.4.1 Processamento das previsões numéricas de precipitação da BHPS

Para definição da janela móvel ideal, foi feita a avaliação do  $\overline{CRPS}$  utilizando diferentes tamanhos de janelas de dias antecedentes ao dia de previsão (JAVANSHIRI; FATHI; MOHAMMADI, 2021). A figura 16 mostra a evolução do  $\overline{CRPS}$ , para todo o período de análise, utilizando janelas móveis de 60 até 100 dias para as três técnicas de processamento propostas, nos horizontes de tempo de 24 h a 120 h. Convém mencionar que generalizadamente o  $\overline{CRPS}$  aumenta em função do horizonte de previsão, o que é esperado uma vez que a qualidade da previsão diminui à medida que o horizonte de previsão se amplia.

O resultado melhora ( $\overline{CRPS}$  diminui) conforme a janela amostral se amplia, indicando que a escolha da janela é importante para qualidade da previsão. O modelo GEV apresenta maior instabilidade do que os demais e, apesar da instabilidade, tanto o modelo GEV quanto o CSG mostram estabilidade no valor do coeficiente utilizando janelas maiores ou iguais a 90 dias. No modelo BMA este comportamento é menos evidente, mas ainda assim indica menor redução do  $\overline{CRPS}$  em função da janela de treinamento também perto da janela de 90 dias, destaca-se também que os valores de CRPS no modelo BMA são maiores do que nos outros casos.

Deste modo, foi adotada a janela móvel de 90 dias para o processamento das previsões de precipitação da bacia. Em um teste semelhante ao apresentado, foi verificado que uma janela móvel de 87 dias para ajustar o modelo BMA às previsões de precipitação por ensembles geradas através de mudanças na parametrização do modelo WRF para o Irã (JAVANSHIRI; FATHI; MOHAMMADI, 2021).

Figura 16 – *Continous Rank Probability* (CRPS) em função do tamanho da janela de treinamento (em dias) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna) e para os diferentes modelos probabilísticos (um modelo em cada linha, com cores diferentes).



Fonte: Elaborado pelo autor.

Uma vez definido o tamanho da janela de treinamento, foi feita a avaliação das previsões probabilísticas. A figura 17 apresenta os resultados dos coeficientes determinísticos utilizados para avaliação da qualidade das previsões, para as previsões brutas do ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de superação de 50% da precipitação foi utilizado como referência de previsão determinística.

Para correlação, as previsões brutas do ECMWF apresentaram o melhor desempenho e a BMA o pior, enquanto que a GEV e CSG obtiveram resultados intermediários e semelhantes entre si. Em todos os casos, a correlação diminui com o aumento do horizonte de previsão.

Para o EM, o resultado foi semelhante ao anterior, com as previsões brutas do ECMWF apresentando o melhor resultado, GEV e CSG com comportamento semelhante e resultado intermediário e BMA com o pior desempenho.

O resultado difere para o EMA, neste caso GEV e CSG apresentaram o melhor resultado, enquanto as previsões brutas do ECMWF tem resultado intermediário e mais uma vez o BMA apresentou o pior desempenho.

Figura 17 – Coeficientes determinísticos para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja). Para o ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de superação de 50% como referência de previsão determinística



O Brier Score (Figura 18) foi calculado considerando os limiares de 0,1 mm, 5 mm, 10 mm e 15 mm. Em todos os casos as previsões brutas do ECMWF apresentaram melhor desempenho (valores mais próximos de zero) do que as previsões processadas. Também neste coeficiente os modelos GEV e CSG apresentaram resultados semelhantes e desempenho intermediário em relação aos demais e o BMA apresentou o pior desempenho.

Figura 18 – Brier Score para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja) utilizando os limiares de 0,1 mm, 5 mm, 10 mm e 15 mm para discriminação de eventos.



Fonte: elaborado pelo autor

Para as previsões brutas do ECMWF, os *rank histograms* de todos os horizontes de tempo apresentam formato de "L"(figura 19). Este formato indica viés positivo nos membros do conjunto, indicando que as observações ocupam com maior frequência a posição abaixo dos membros do conjunto no histograma, ou então que as previsões frequentemente superestimam a observação. À medida que o horizonte de previsão se amplia, o padrão de dispersão apresenta discreta atenuação, uma vez que a frequência de observações no primeiro intervalo de classe reduz.





Fonte: Elaborado pelo autor.

Para permitir a comparação entre o *rank histograms* das previsões brutas com os PIT *histograms* das previsões processadas, foi utilizado o mesmo número de classes (10). A figura 20 apresenta o resultado para a chuva processada com os três modelos probabilísticos propostos.

Para o modelo BMA, nota-se que os histogramas apresentam um padrão do tipo "U" no qual a chuva observada se posiciona nos extremos do histograma com maior frequência. Este padrão indica que o processamento causou concentração dos membros do conjunto de modo que as observações frequentemente superam ou ficam abaixo das previsões. Este padrão é semelhante em todos os horizontes de tempo.

Para o caso das previsões processadas com o modelo GEV, os histogramas apresentam padrão tipo L. Este comportamento mostra que há concentração de parte das observações nas classes inferiores do histograma, ou seja, a previsão frequentemente superestima a chuva (viés úmido).

O processamento com o modelo CSG apresenta o comportamento mais próximo do ideal, indicando uma condição em que os membros são equiprováveis, com dispersão adequada. Comparando o resultado do modelo CSG com os demais modelos e com a previsão bruta, este modelo apresentou o melhor resultado em termos de dispersão dos membros do conjunto.

Figura 20 – Probability Integral Transform histogram (PIT) dos modelos BMA (azul), GEV (verde) e CSG (laranja) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna). A linha horizontal tracejada indica o comportamento desejado do gráfico de barras, no qual todas as



Fonte: Elaborado pelo autor.

As figuras 21 a 24 apresentam o diagrama de confiabilidade da previsão bruta do ECMWF e das previsões processadas, para diferentes limiares de precipitação. Para o limiar de 0,1 mm (figura 21) com antecipação de 24 horas, a curva de calibração da previsão bruta indica que a previsão é subestimada (superestimada) para frequência condicional de observação baixa (alta). As previsões com 72 horas de antecipação se mostram mais alinhadas em relação à reta 1:1. O gráfico de refinamento da distribuição mostra que as previsões brutas se concentram nas classes com baixa (classe 1) e alta (classe 10) probabilidade de ocorrência, o que é indicativo de pouca incerteza. Este padrão da curva de refinamento é mantido em todos os horizontes de previsão. A curva de calibração das previsões processadas com BMA mostra que o modelo não detecta as três primeiras classes de probabilidade de previsão (ou seja, o modelo não detecta previsões com baixa probabilidade de ocorrência) em nenhum dos horizontes de previsão. O comportamento para previsões com probabilidade de previsão de intermediária a alta indica previsões com viés positivo. O refinamento da distribuição apresenta padrão bimodal, com picos nas classes 5 e 10, de modo que as previsões estão concentradas nas classes de probabilidade de previsão intermediária e alta. O padrão da curva de calibração e do refinamento da distribuição é semelhante em todos os horizontes de previsão e indica confiança intermediária das previsões realizadas com este modelo.

Para o caso das previsões processadas com o modelo GEV, a curva de calibração apresenta viés úmido, porém melhor alinhado à reta 1:1 quando comparada com os resultados anteriores. O padrão do gráfico de refinamento da distribuição apresenta concentração das previsões na frequência mais baixa e nas classes de frequência alta. Este padrão indica que o modelo prevê a ocorrência de eventos com diferentes probabilidades e que as amostras utilizadas para determinação de cada um dos pontos da curva de calibração são semelhantes entre si e, neste caso, a confiança do modelo de previsão é intermediária.

A curva de calibração do modelo CSG, indica viés úmido, com desempenho semelhante ao modelo GEV. O padrão da curva de calibração é semelhante nos diferentes horizontes de previsão. O gráfico de refinamento da distribuição é semelhante em todos os horizontes de previsão, apresentando frequência amostral bem distribuída nas classes. Este padrão do gráfico de refinamento da distribuição indica que as amostras utilizadas na determinação da curva de calibração são semelhantes e está associado à alta incerteza na previsão.

Figura 21 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 0,1 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado.



Fonte: Elaborado pelo autor.

Para o limiar de 5 mm a curva de calibração da previsão bruta do ECMWF indica previsões com viés seco, principalmente para a probabilidade de previsão maior. O padrão da curva de calibração melhora discretamente (mais próximo da reta 1:1) com o horizonte de previsão. O gráfico de refinamento da distribuição mostra que as previsões se concentram nas classes com baixa (classe 1) e alta (classe 10) probabilidade de ocorrência o que é indicativo de baixa incerteza.

As previsões ajustadas com o modelo BMA detectam apenas a primeiras classes de probabilidade de previsão de modo que não é possível avaliar o diagrama de confiabilidade para a BMA.

Para o caso das previsões ajustadas ao modelo GEV, a curva de calibração apresenta boa concordância com o alinhamento ideal. O padrão do gráfico de refinamento da distribuição indica concentração das previsões na classe de baixa probabilidade de previsão.

O modelo CSG, assim como o GEV, apresenta curva de calibração com bom alinhamento e proximidade da reta 1:1. O padrão da curva de calibração é bem semelhante nos diferentes horizontes de previsão. O padrão do gráfico de refinamento da distribuição também indica concentração das previsões na classe de baixa probabilidade de previsão.

Figura 22 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 5 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado.



Fonte: Elaborado pelo autor.

A curva de calibração da previsão bruta para o limiar de 10 mm indica previsões com viés seco. O gráfico de refinamento da distribuição indica concentração das previsões na primeira classe. As previsões do modelo BMA apresentam o mesmo problema do limiar anterior e detectam apenas a primeiras classes de probabilidade de previsão de modo que não é possível avaliar o diagrama de confiabilidade para a BMA.

O modelo GEV apresenta bom alinhamento em relação à reta 1:1 no horizonte de 24 h, com viés úmido. Nos demais horizontes de previsão o alinhamento não é tão bom. O gráfico de refinamento apresenta contagem de amostras concentradas na primeira classe. O resultado do modelo CSG apresenta padrão semelhante ao anterior, com bom alinhamento e viés úmido, no horizonte de 24 h. O gráfico de refinamento da dispersão também apresenta contagem de amostras concentradas na primeira classe.

Figura 23 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 10 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento



Fonte: Elaborado pelo autor.

Para o limiar de 15 mm, as previsões brutas indicam que a previsão é de baixa resolução. O gráfico de refinamento da distribuição indica amostras concentradas na primeira classe. Para as previsões ajustadas ao modelo BMA, o mesmo problema dos limiares anteriores ocorre neste caso. Tanto o modelo GEV quanto o CSG apresentam curva de calibração com comportamento errático, que não segue os padrões que

permitem avaliar a previsão e o gráfico de refinamento da distribuição indica amostras concentradas na primeira classe.

Figura 24 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 15 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado.



Fonte: Elaborado pelo autor.

A figura 25 apresenta a curva ROC considerando os limiares de 0,1 mm, 5 mm, 10 mm e 15 mm. Notadamente, o comportamento da previsão do ECMWF bruta é melhor que as demais. Entre os modelos probabilísticos utilizados, se destaca o modelo CSG, que apresentou desempenho ligeiramente superior aos modelos BMA e GEV. Também se destaca que a qualidade das previsões diminui consideravelmente à medida que o limiar de chuva aumenta e, no caso dos modelos probabilísticos, não há capacidade de previsão para o limiar de 15 mm. Embora a previsão bruta do ECMWF também sofra com o aumento do limiar de chuva utilizado, ainda assim o seu comportamento é melhor que os demais. Em termos de ampliação do horizonte de previsão para um mesmo percentil, a qualidade das previsões é praticamente constante. Figura 25 – Curva ROC para chuvas acima de 0,1 mm, 5 mm, 10 mm e 15 mm, para previsões com horizontes de 24 h a 120 h. A curva apresenta no eixo X a probabilidade de alarme falso e no eixo Y a probabilidade de detecção do evento, sendo representado conjuntamente a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A reta identidade indica a climatologia e a curva ideal deve ficar acima e o mais distante possível da identidade



Fonte: Elaborado pelo autor.

Os resultados apresentados nesta seção mostram que o processamento das previsões numéricas de precipitação, principalmente com os modelos GEV e CSG, melhoram as métricas que avaliam a previsão por conjunto, tanto na distribuição dos membros quanto na confiabilidade das previsões.

## 4.5 Previsões de vazão na Bacia Hidrográfica do Rio Paraíba do Sul

Neste item são apresentados os resultados das previsões de vazão realizadas para a bacia do rio Paraíba do Sul. É feita a comparação entre as previsões sem correção e com a vazão corrigida, utilizando tanto as previsões de precipitação brutas, quanto as previsões processadas. Antes disso, é apresentada uma comparação dos erros entre as previsões sem correção e corrigidas, com o objetivo de expor a condição de viés que foi detectado durante o desenvolvimento dos experimentos.

## 4.5.1 Comparação entre a previsão ajustada e sem ajuste

As previsões de vazão realizadas continuamente (dia a dia) no período de 03/01/2018 até 17/10/2019 (653 dias) para os horizontes de previsão de 24 h a 120 h (5 horizontes de tempo), alimentando tanto com a previsão controle do ECMWF quanto com os membros perturbados (51 membros), além dos quantis de probabilidade de cada um dos modelos probabilísticos utilizados (30 membros), totalizando 264.465 simulações.

A figura 26 apresenta o erro percentual da previsão de 24 h a 120 h para os postos fluviométricos da bacia, com o modelo hidrológico alimentado com as previsões brutas do ECMWF. A previsão sem ajuste se refere à vazão de saída do modelo e a previsão ajustada corresponde às previsões após a aplicação do ajuste proposto no item 3.3.1.

A previsão sem ajuste apresenta um viés negativo sistemático em todas as estações de monitoramento e para todos os horizontes de previsão. O ajuste nas previsões reduz esse viés, resultando em erros predominantemente próximos de zero. No entanto, a previsão ajustada amplia os valores extremos de erro, ocasionando superestimativa das vazões, que se amplia em função do horizonte de previsão.



Figura 26 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste para os postos de monitoramento fluviométrico da bacia do rio Paraíba do Sul (linhas) para horizontes de previsão de 24 h a 120 h (colunas). O gradiente de cores indica o percentil das amostras associadas ao erro encontrado.

Fonte: Elaborado pelo autor.

Conforme pode ser visto na figura 27, que apresenta o erro percentual por trimestre para a estação Santa Cecília Jusante, a condição descrita anteriormente é proeminente no trimestre junho-julho-agosto (JJA), no qual o ajuste proposto ampliou drasticamente os valores extremos de erro. Quanto ao trimestre DJF, a previsão ajustada apresenta o menor erro percentual e melhora o viés das previsões sem ajuste, destaca-se que neste trimestre as previsões sem ajuste se apresentam com o maior viés seco. Para o trimestre MAM o erro percentual das previsões ajustadas se amplia assim como no trimestre SON. Ainda no trimestre SON também é possível notar que para o horizonte de 24 h o ajuste proposto melhora o viés das previsões. Este resultado mostra que o ajuste proposto é interessante para melhorar a qualidade das previsões no trimestre DJF que corresponde ao trimestre mais chuvoso da bacia, no qual se concentram as ocorrências de picos de vazão. Já o trimestre JJA é o mais seco da bacia.

Figura 27 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste do posto de monitoramento fluviométrico Santa Cecília para horizontes de previsão de 24 h a 120 h (linhas) separados de acordo com trimestres (colunas) DJF (dezembro- janeiro – fevereiro), MAM (março – abril – maio), JJA (junho- julho- agosto) e SON (setembro – outubro – novembro). O gradiente de cores indica o percentil das amostras associadas ao erro encontrado



Fonte: Elaborado pelo autor.

#### 4.5.2 Comparação entre as previsões de vazão bruta e probabilísticas

Os resultados das previsões de vazão, geradas a partir das previsões de precipitação bruta e das precipitações processadas, com e sem o ajuste da vazão de saída, apresentados neste item, referem-se ao posto Santa Cecília. Este é o posto mais a jusante da bacia e representa o comportamento médio do escoamento à montante. A análise dos demais postos de monitoramento fluviométrico é mostrada no Anexo C.

A figura 28 apresenta o resultado dos coeficientes determinísticos para o posto Santa Cecília. Analisando primeiramente as previsões sem ajuste, se verifica que o posto Santa Cecília apresenta maior variação entre a previsão bruta do ECMWF de 24 h e de 120 h, iniciando com uma correlação de 0,74 e terminando com 0,32. Já as previsões geradas com os quantis de probabilidade apresentam menor variação entre 24 h e 120 h, iniciando com 0,79 e finalizando com 0,66.

Nas previsões com a vazão ajustada no posto Santa Cecília, as previsões processadas tem correlação variando entre 0,68 e 0,70 no horizonte de 24 h, no horizonte de 48 h sobe para 0,87 com os modelos GEV e CSG e para 0,93 com o modelo BMA, nos demais horizontes a correlação reduz chegando a 0,70 (com os modelos GEV e CSG) e 0,87 (com o modelo BMA) no horizonte de 120 h. Já a previsão bruta do ECMWF tem correlações variando entre 0,50 (no horizonte de 24 h) e -0,30 (no horizonte de 120 h).

O comportamento das vazões sem ajuste mostra que a correlação diminui à medida que o horizonte de previsão aumenta e em todos os casos se observa que todas as previsões se iniciam com valor de correlação próximo, uma vez que há maior influência das condições iniciais e à medida que o horizonte de previsão avança a correlação da previsão de vazão realizada com a previsão bruta do ECMWF diminui mais rapidamente do que as previsões geradas com os modelos probabilísticos propostos.

Para as previsões ajustadas se destaca que a correlação aumenta consideravelmente em todos os postos de monitoramento para as previsões processadas com os modelos probabilísticos e que há um padrão de aumento da correlação entre o horizonte de tempo de 24 h e 48 h. As previsões geradas com quantis de probabilidade também mostram aumento da correlação em função do aumento da área de drenagem. A correlação para as previsões brutas do ECMWF são baixas, ficando próxima de zero e, em alguns casos, negativas.

O valor do erro médio absoluto em função do horizonte de previsão no posto Santa Cecília aumenta em função do aumento do horizonte de previsão, no qual as previsões processadas (previsões brutas do ECMWF) apresentam erro de 118  $m^3s^{-1}$  (110  $m^3s^{-1}$ ) para o horizonte de 24 h e de 145  $m^3s^{-1}$  (133  $m^3s^{-1}$ ) para o horizonte de 120 h. Somente no posto Santa Cecília a diferença de comportamento entre as previsões de vazão com base na previsão de chuva processada e as previsões brutas do ECMWF foi proeminente.

Para as previsões ajustadas o erro médio absoluto no posto Santa Cecília também aumenta em função do aumento do horizonte de previsão, no qual as previsões processadas apresentam erro de 59,6  $m^3s^{-1}$ para o horizonte de 24 h e de 183,0  $m^3s^{-1}$ para o horizonte de 120 h e para a previsão bruta do ECMWF a variação é de 98,8  $m^3s^{-1}$  para 580,3  $m^3s^{-1}$  entre os horizontes de 24 h e 120 h.

De modo geral, o erro médio absoluto para as previsões sem ajuste se comporta de maneira semelhante, tanto para previsões brutas do ECMWF quanto para previsões geradas por quantis de probabilidade. O erro médio absoluto também aumenta ligeiramente em função do horizonte de previsão. Para as previsões ajustadas é notória a distinção de comportamento das previsões brutas do ECMWF e das previsões processadas, na primeira o erro médio absoluto apresenta maior magnitude e maior aumento do erro em função do horizonte de previsão quando comparada com a segunda.

O resultado do erro médio para às previsões sem ajuste no posto Santa Cecília, mostra que o erro médio aumenta em função do horizonte de previsão para previsões processadas, sendo 113,4  $m^3 s^{-1}$  o erro para 24 h e 144,3  $m^3 s^{-1}$  para 120 h, já o erro para as previsões brutas do ECMWF apresentam redução de 98,7  $m^3 s^{-1}$  para 60,5  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h.

Para as previsões ajustadas, a previsão bruta do ECMWF tem variação de 11,2  $m^3 s^{-1}$  para -340,1  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h e as previsões processadas apresentam erro médio de 26,4  $m^3 s^{-1}$  (GEV e CSG) e 35,1  $m^3 s^{-1}$  (BMA) para o horizonte de 24 h e de 144,7 (GEV e CSG) e 183,0 (BMA) para o horizonte de 120 h.

Dos resultados apresentados é possível notar que as previsões brutas do ECMWF com a vazão de saída ajustada apresentam viés negativo e, em geral, a magnitude do erro é alta, sendo que a magnitude do erro médio aumenta em função do horizonte de previsão, de modo que a previsão bruta do ECMWF sem ajuste da vazão de saída apresenta desempenho melhor do que

com a vazão de saída ajustada. A respeito das previsões processadas, ainda que em alguns casos, nos primeiros horizontes (24 h a 48 h), o desempenho da previsão processada sem ajuste da vazão de saída tenha desempenho comparável às previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída é a que apresentou o melhor desempenho.

Figura 28 – Coeficiente de correlação (R<sup>2</sup>), Erro Médio Absoluto (EMA) e Erro Médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste para o posto Santa Cecília



Fonte: Elaborado pelo autor.

A figura 29 apresenta o resultado do BS, considerando como limiar de cheia o percentil 75% da vazão, e o CRPS para o posto Santa Cecília. O comportamento do posto Santa Cecília é representativo dos demais postos da bacia. Para a vazão sem ajuste o modelo BMA e as previsões brutas dos ECMWF são semelhantes, nas quais a variação do BS foi de 0,18 a 0,23 no primeiro caso e de 0,16 a 0,24 no segundo, ambos para previsões entre os horizontes de 24 h e 120 h. Para o processamento com os modelos GEV e CSG sem ajuste da vazão de saída o coeficiente é constante próximo de 0,14 em todos os horizontes de previsão.

Para as previsões ajustadas há mudança no comportamento. O coeficiente para o modelo BMA varia de 0,06 a 0,18 entre os horizontes de 24 h e 120 h, as previsões brutas do ECMWF a variação foi de 0,13 a 0,38 entre 24 h e 120 h e as previsões com os modelos GEV e CSG se comportando de modo semelhante, com coeficiente variando entre 0,05 e 0,10 do horizonte de previsão 24 h até 120 h.

O resultado do CRPS para as previsões sem ajuste mostra que o coeficiente varia entre  $95 m^3 s^{-1}$  e  $110 m^3 s^{-1}$  para os horizontes de 24 h a 120 h para as previsões brutas enquanto que para as previsões processadas a variação é entre  $95 m^3 s^{-1}$  e  $125 m^3 s^{-1}$ , sem ser possível distinguir o comportamento entre os modelos probabilísticos.

As previsões ajustadas apresentam um comportamento diferente, principalmente para as previsões brutas do ECMWF, nas quais a magnitude e a variação do CRPS são maiores do que nas previsões processadas. O CRPS das previsões brutas no horizonte de 24 h é de 88,2  $m^3s^{-1}$  e aumenta linearmente até 236,9  $m^3s^{-1}$  no horizonte de 120 h e das previsões processadas é de 51,4  $m^3s^{-1}$  para 24 h, reduz para 48,9  $m^3s^{-1}$  no horizonte de 48 h e aumenta linearmente até 66,2  $m^3s^{-1}$  no horizonte de 120 h.

O resultado do BS mostra que as previsões geradas com os modelos probabilísticos GEV e CSG tem menor variação nos valores de BS em função do horizonte de previsão. As previsões processadas com o modelo probabilístico BMA e as previsões brutas do ECMWF apresentam aumento no BS em função do horizonte de tempo quando comparada com as previsões processadas com os modelos GEV e CSG. Este resultado é valido tanto para as previsões com a vazão sem ajuste da vazão de saída quanto com ajuste das vazões de saída, porém, para as previsões com ajuste da vazão de saída o resultado apresenta valores de BS mais próximos de zero, ou seja, o desempenho das previsões processadas com os modelos GEV e CSG e com as vazões de saída ajustadas apresentam o melhor desempenho de previsão. Os resultados do CRPS mostram que as previsões processadas sem ajuste da vazão possuem erros semelhantes ao encontrado para a previsão bruta do ECMWF. Já as previsões processadas (independe do modelo utilizado) e com a vazão de saída ajustada possuem os menores valores de CRPS, indicando que esta categoria de previsão apresenta o menor erro entre o que foi avaliado. As previsões com a chuva processada e com a vazão ajustada também apresentaram menor variação do CRPS em função do horizonte de previsão.

Figura 29 – *Brier Score* (BS) considerando como limiar de cheia o percentil 75% da vazão e Continous Ranked Probability Score (CRPS), entre vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste, para o posto Santa Cecília.



Fonte: Elaborado pelo autor.

A curva ROC para previsões de vazão é mostrada na figura 30. As curvas das previsões ajustadas indicam um resultado melhor do que as previsões sem ajustes. O comportamento da curva para a previsão gerada com o modelo BMA é a que apresenta o padrão mais próximo do ideal, seguida das curvas para a previsão gerada com os modelos GEV e CSG. A capacidade de discriminação dos modelos diminui em função do horizonte de previsão, sendo que esta redução de discriminação dos modelos é mais destacada nas previsões brutas do ECMWF (sem ajuste e ajustadas) e mais discreta nas previsões geradas com os modelos probabilísticos com a vazão ajustada.

Este resultado indica que o ajuste com os modelos probabilísticos melhora a capacidade de discriminação das previsões de vazão quando comparada com a previsão bruta do ECMWF, sendo que o modelo BMA foi o que apresentou a melhor capacidade de discriminação.

Figura 30 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às previsões sem ajuste da vazão (ajustada).



Fonte: Elaborado pelo autor.

A figura 31 mostra o diagrama de confiabilidade da previsão de vazão utilizando a precipitação bruta do ECMWF e com a precipitação processada, em ambos os casos com a vazão de saída ajustada. Foi considerado o percentil 75% da vazão como limiar para ocorrência de eventos. Os resultados sem ajuste da vazão de saída são em todas as condições piores do que com ajuste da vazão de saída e por brevidade as figuras foram omitidas.

O resultado da curva de calibração para previsões de vazão com a previsão de precipitação bruta do ECMWF apresenta baixa resolução em todos os horizontes de previsão. A

curva de calibração da previsão de vazão utilizando a precipitação processada com o modelo BMA tem o pior desempenho entre as técnicas de processamento.

A curva de calibração para o horizonte de 24 h apresenta bom ajuste para probabilidades de previsão baixa a intermediária para o processamento com os modelos GEV e CSG. Para os demais horizontes (48 h a 120 h) as previsões de probabilidade de previsão baixa (alta) possui viés úmido (seco) padrão que indica boa resolução dos modelos GEV e CSG.

Os gráficos de refinamento da distribuição indicam boa confiança tanto das previsões brutas quanto dos modelos de previsão

Figura 31 – Diagrama de Confiabilidade (*Reliability Diagram*) da estação Santa Cecília utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado



Fonte: Elaborado pelo autor.

Os *rank histograms* para a previsão gerada com o modelo hidrológico alimentado com as previsões brutas do ECMWF para horizontes de previsão de 24 h a 120 h e com a vazão de saída ajustada, são apresentados na figura 32. A primeira classe do histograma indica a frequência com que a vazão observada ficou próxima ou abaixo dos membros que indicam menor vazão, enquanto a última classe indica a frequência com que a vazão prevista pelos membros que indicam maior precipitação.

Os *rank histograms* de todos os horizontes de tempo apresentam formato de "U". Este tipo de formato indica concentração excessiva dos membros do conjunto de modo que os membros pouco espalhados e implicam em observações se posicionadas frequentemente nas classes extremas. Neste caso há excesso de confiança na previsão, cujos membros indicam valores semelhantes entre si. O resultado é bem semelhante em todas as estações de monitoramento da bacia e em todos os horizontes de tempo de previsão.

Figura 32 – *Rank Histogram* para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.



Fonte: Elaborado pelo autor.

Para permitir a comparação entre o *rank histograms* das previsões brutas com os PIT *histograms* das previsões processadas, foi utilizado o mesmo número de classes (10). A figura 33 apresenta o resultado para a previsão de vazão com o modelo hidrológico alimentado com a chuva processada utilizando os modelos BMA, GEV e CSG e vazão de saída ajustada. Nota-se que os histogramas apresentam um padrão do tipo "U" para o resultado do modelo BMA. O resultado com os modelos GEV e CSG apresentam comportamento semelhante entre si. Nestes, o padrão indica concentração de observações na primeira classe, indicando que há um grande número de casos em que as observações são menores que a menor previsão, combinado com um padrão de "rampa", com as observações se posicionando majoritariamente entre a probabilidade de intermediária à alta.

O resultado do PIT *histogram* não é o ideal, contudo, comparado com as previsões brutas do ECMWF, há melhora na qualidade da previsão de vazão (especificamente na dispersão dos membros do conjunto) utilizando a precipitação processada com o modelo GEV e CSG.



Figura 33 – PIT *histogram* para previsões de precipitação processadas da BRPS em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.

Fonte: Elaborado pelo autor.

#### 4.5.3 Hidrogramas de previsão da máxima registrada

A tabela 13 apresenta o dia de ocorrência e o valor da vazão máxima diária em cada posto fluviométrico utilizado. Neste item é mostrado o resultado para o posto Santa Cecília, a análise completa de todos os postos da bacia consta no anexo C. Somente nos postos Ponte Alta I e Santa Branca o evento da máxima está em datas próximas, de modo que a máxima nestes postos foi ocasionada pela mesma precipitação.

Posto de monitoramento	Data da máxima	Vazão registrada ( $m^3 s^{-1}$ )
Ponte Alta I	08/11/2018	75,8
Cunha	22/03/2018	48,1
São Luís do Paraitinga	19/03/2019	98,6
Santa Branca	09/11/2018	277,1
Santa Cecília	05/03/2018	785,6

Tabela 13 – Data e valor da vazão máxima registrada no período de estudo em cada posto de monitoramento.

Fonte: Elaborado pelo autor.

A figura 34 apresenta os hidrogramas de previsão para o posto Santa Cecília. Para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e sem ajuste da vazão de saída, todos os membros subestimam a vazão observada no posto e há concentração dos membros. O mesmo padrão é observado para as previsões com a vazão de saída ajustada. Tanto na previsão sem ajuste quando na previsão com ajuste da vazão de saída, há alguma melhora no espalhamento dos membros em função do aumento do horizonte de previsão, contudo, insuficiente para conferir melhora na qualidade da previsão.

As previsões alimentadas com as previsões processadas com o modelo BMA seguem o mesmo padrão dos demais postos, com pouco espalhamento dos membros (sem ajuste e com ajuste da vazão de saída). A previsão sem ajuste não representa nenhuma capacidade de previsão. Já a previsão ajustada nota-se que há melhora das subestimativas de vazão nos horizontes de 48 h a 120 h (quando comparadas com a previsão bruta do ECMWF).

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída mostra melhora no espalhamento em relação às previsões brutas do ECMWF. Entre os horizontes de 24 h a 96 h todos os quantis de previsão ficam abaixo da vazão observada. Para o horizonte 120 h a vazão observada fica entre os quantis de 85% e 95%. O ajuste da vazão de saída melhora a previsão. Para o horizonte de 24 h a vazão observada fica entre os guantis de saída melhora a previsão.

do quantil de 95%, no horizonte de 48 h a vazão observada fica entre os quantis de 65% e 75%, para as previsões com 72 h a 120 h de antecedência, a vazão observada fica entre os quantis 55% e 65%.

O resultado para as previsões processadas com o modelo CSG o resultado é semelhante ao anterior. Para a previsão sem ajuste da vazão de saída nos horizontes de 24 h a 96 h todos os quantis de previsão ficam abaixo da vazão observada e no horizonte de 120 h a vazão observada fica entre os quantis de 85% e 95%. O ajuste da vazão de saída melhora o espalhamento em relação à vazão sem ajuste. Para o horizonte de 24 h a vazão observada fica entre os quantis de 85% e 95%, nos horizontes de 48 h a 120 h a vazão observada fica entre os quantis de 65% e 75%.



Figura 34 – Hidrogramas de previsão da vazão máxima diária do período de estudo para o posto Santa Cecília. A linha tracejada horizontal indica o dia do evento e a linha tracejada em vermelho a vazão

Fonte: Elaborado pelo autor.

#### 4.6 Resumo e conclusões do capítulo

Neste capítulo foi apresentada a caracterização fisiográfica da bacia, os resultados da modelagem hidrológica, a avaliação da previsão de chuva para bacia (bruta e processada) e os resultados da previsão de vazão. A região é caracterizada pelo relevo acidentado, verão chuvoso e inverno seco e cuja vazão responde de forma rápida e acentuada à precipitação. A cobertura da bacia é composta majoritariamente por área florestal e uso agrícola seguido por áreas urbanas.

Foram verificados quais dos parâmetros de calibração do SWAT são estatisticamente sensíveis para o processo de transformação de chuva em vazão, sendo que quatro destes estão diretamente relacionados com a geração de escoamento (CN2, SURLAG, LAT\_TIME, OV\_N) e dois atuam de forma indireta (ESCO, SOL\_AWC, CANMX) na geração de escoamento.

O resultado da calibração e verificação foi realizado utilizando os coeficientes NSE, KGE, R, RMSE, EMA e EM, além dos gráficos de dispersão e dos hidrogramas simulado e observado da bacia. O modelo hidrológico apresentou resultados aceitáveis em três dos cinco postos utilizados (Santa Cecília, São Luís do Paraitinga e Santa Branca). Os demais postos apresentaram limitações para representação do processo de transformação de chuva em vazão. O desempenho do modelo melhora em função do aumento da área de drenagem enquanto os postos com maior limitação apresentam as menores áreas de drenagem.

O processamento da previsão de precipitação para a bacia foi realizado utilizando a janela de treinamento de 90 dias, definida de acordo com a variação do *CRPS* em função da janela de treinamento utilizada no processamento da precipitação. As métricas determinísticas não indicam diferenças relevantes entre a previsão de precipitação bruta do ECMWF e o processamento com os modelos GEV e CSG, contudo, ao considerar métricas que avaliam a distribuição do conjunto (previsões probabilísticas) os resultados mostram que o desempenho das previsões processadas com os modelos GEV e CSG apresentam desempenho melhor do que as previsões brutas do ECMWF. Em termos de capacidade de discriminação dos eventos, o processamento não mostrou melhora e destaca-se principalmente a melhora na dispersão e na confiabilidade das previsões de precipitação processadas com os modelos GEV e CSG.

Foram avaliadas as previsões de vazão quando o modelo hidrológico foi alimentado com as previsões de precipitação brutas do ECMWF e com as previsões processadas com os modelos BMA, GEV e CSG. Para as previsões probabilísticas, foi realizado utilizando os quantis de probabilidade de superação da precipitação de 5% a 95% a cada 10% para alimentar o modelo hidrológico.

Também foi testada uma estratégia de correção da vazão de saída do modelo hidrológico para contornar o problema de condição inicial da vazão simulada, na qual as vazões previstas são ajustadas de acordo com a tendência indicada pelas vazões simuladas nos horizontes de 24 h a 120 h.

Avaliando os coeficientes determinísticos, a correlação (R) para previsão sem ajuste da vazão de saída apresenta resultados melhores para as previsões processadas quando comparadas com as previsões de vazão realizadas com as previsões de chuva brutas do ECMWF. Contudo, não há diferença relevante entre os modelos de processamento (BMA, GEV e CSG). Quando a vazão de saída é ajustada, o desempenho das previsões de vazão realizadas com as previsões de chuva brutas do ECMWF é inferior ao resultado sem ajuste da vazão de saída, já as previsões com a chuva processada apresentam não só desempenho superior às condições sem ajuste, mas também o melhor desempenho entre todas as previsões.

De modo geral, o EMA para as previsões sem ajuste da vazão de saída se comportam de maneira semelhante, tanto paras as previsões brutas do ECMWF quanto para as previsões processadas. Para as previsões ajustadas é notória a distinção de comportamento das previsões brutas do ECMWF e das previsões processadas, sendo que na primeira o EMA apresenta maior magnitude e maior aumento do erro em função do horizonte de previsão quando comparada com a segunda.

Avaliando o EM, as previsões brutas do ECMWF sem ajuste da vazão de saída apresentam desempenho superior àqueles geradas a partir das previsões de chuva processada. Para as previsões com a vazão de saída ajustada, a magnitude do EM para previsão bruta do ECMWF é maior do que sem ajuste da vazão de saída. A respeito das previsões processadas, ainda que em alguns casos, nos primeiros horizontes (24 h a 48 h), o desempenho da previsão processada sem ajuste da vazão de saída tenha desempenho comparável às previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída são as que apresentaram o melhor desempenho na maior parte dos casos.

O resultado do BS foi calculado utilizando o percentil de 75% como limiar para detecção dos eventos. O resultado mostra que, majoritariamente, as previsões de vazão geradas com a chuva processada possuem desempenho superior às previsões de vazão geradas a partir de

previsões brutas de chuva do ECMWF (com exceção da chuva processada com modelo BMA e sem ajuste da vazão de saída, que possui desempenho semelhante à previsão bruta do ECMWF). É importante mencionar que o desempenho do BS para previsão de chuva, em nenhum dos limiares, indicou desempenho superior da chuva processada. No entanto, ao analisar as previsões de vazão geradas a partir da chuva processada o resultado se inverteu.

Os resultados do CRPS mostram que as previsões processadas sem ajuste da vazão de saída possuem erro semelhante ao encontrado para a previsão bruta do ECMWF, enquanto as previsões processadas (independe do modelo utilizado) e com a vazão de saída ajustada possuem melhor desempenho, indicando que esta categoria de previsão apresenta o menor erro entre o que foi avaliado.

A curva ROC também evidenciou que o processamento da precipitação beneficiou a capacidade de detecção de eventos, tanto com a vazão de saída sem ajuste quanto com a vazão de saída ajustada, quando comparadas com a previsão de vazão gerada a partir das previsões brutas do ECMWF. A previsão com a vazão de saída ajustada gerada com a chuva processada apresentou as curvas mais próximas do comportamento ideal, principalmente o modelo BMA.

A confiabilidade das previsões de vazão, indicada pelo diagrama de confiabilidade (neste caso elaborado considerando o percentil 75% da vazão como limiar para ocorrência de eventos) mostra que os resultados sem ajuste da vazão de saída são, em todas as condições, piores do que com ajuste da vazão de saída. Contudo, o ajuste das vazões e o processamento da precipitação não foram suficientes para indicar que houve melhora generalizada na confiabilidade das previsões.

Em termos de espalhamento dos membros, o processamento da precipitação faz com que as previsões passem de um padrão em "U" (indicando concentração dos membros do conjunto) para um padrão em rampa que indica viés negativo das previsões em relação ao observado.

A análise dos hidrogramas da máxima registrada no período sintetiza grande parte do que foi discutido. O ajuste da vazão de saída melhora a qualidade das previsões tanto quando o modelo hidrológico é alimentado com as previsões brutas do ECMWF, como quando é alimentado pelos quantis de probabilidade das previsões processadas. O processamento com a BMA promove alguma melhora na previsão, porém, os quantis de probabilidade estão muito próximos, de modo que não é possível distinguir os quantis nos hidrogramas de previsão. Ou seja, os quantis de probabilidade estão muito concentrados em torno do mesmo valor e explicam
o fato de que o processamento com a BMA melhora as estatísticas descritivas, mas é penalizado nas estatísticas que consideram o espalhamento dos membros. Por sua vez, o processamento com a GEV e com CSG mostram melhora no espalhamento dos quantis, que na maior parte dos casos (maioria dos postos fluviométricos e horizontes de previsão) formam um hidrograma de previsão que envolve o hidrograma observado. Entre os modelos GEV e CSG, o segundo é o que apresenta o melhor desempenho.

# 5 PREVISÕES HIDROLÓGICAS PARA BACIA HIDROGRÁFICA DO RIO CAÍ

Este capítulo apresenta a aplicação da metodologia proposta para a bacia hidrográfica do rio Caí (BHRC). Inicialmente são apresentadas as características físicas da bacia, seguido pelos resultados da modelagem hidrológica, incluindo o pré-processamento do modelo hidrológico, análise de sensibilidade, da calibração e da verificação do modelo. Posteriormente é apresentada a avaliação da previsão de chuva para bacia e por fim os resultados da previsão de vazão para os postos fluviométricos da bacia.

## 5.1 Características da BHRC

O principal curso d'água da BHRC é o rio Caí que tem sua nascente no município de São Francisco de Paula (RS) e percorre cerca de 230 km até sua foz no rio Jacuí. A área de drenagem da BHRC definida neste trabalho (figura 35) possui 4.983 km<sup>2</sup>.

A área de drenagem da BHRC possui população aproximada de 656.577 habitantes, distribuídos nos 41 municípios inseridos total ou parcialmente na BHRC (SEMA, 2020).

A BHRC é dividida em três trechos: o alto Caí que compreende o trecho entre a nascente até o encontro com o rio Piaí, sendo o trecho com maior declividade e escoamento rápido, o médio Caí que se inicia na foz do rio Piaí e se estende até o município de São Sebastião do Caí, em que no percurso há alternância entre trechos com escoamento rápido e lento, e o baixo Caí que compreende o trecho entre São Sebastião e a foz do Caí que apresenta relevo plano, com escoamento em baixas velocidades em que pode ser observado remanso (SEMA, 2020).



Figura 35 – Localização bacia hidrográfica do Rio Caí (BHRC)

Fonte: Elaborado pelo autor. Limites de bacia e hidrografia (ANA, 2012) e divisões políticas (IBGE, 2020)

De acordo com o levantamento do Mapbiomas de 2019 a cobertura da superfície na BHRC (figura 36) é composta majoritariamente por formação florestal (56%), mosaico de agricultura e pastagem (13%) e formação campestre (12%). Outros usos identificados na bacia são floresta plantada (6%), lavouras temporárias (5%), pastagem (3%), infraestrutura urbana (2%), corpo d'água (1%) e cultivo de soja (1%). Na parte alta da bacia predominam os campos alagados, formação campestre e florestas plantadas, no trecho médio há maior ocorrência de formação florestal e mosaico de agricultura e pastagem. No baixo Caí se concentra a área de lavouras temporárias e onde também ocorre formação campestre e lavouras temporárias.



Figura 36 – Cobertura da superfície da Bacia Hidrográfica do Rio Paraíba do Sul (BHRC)

Fonte: Elaborado pelo autor com informações de uso e cobertura da superfície do Projeto Mapbiomas (2020)

A BHRC possui em sua cabeceira três reservatórios que são utilizados para transposição da água da BHRC para a bacia do Rio dos Sinos com a finalidade de geração de energia elétrica. A Barragem do Salto e a Barragem do Blang estão localizadas no rio Santa Cruz e a Barragem Divisa está instalada no Arroio Divisa.

Estes reservatórios regulam o regime hidrológico do rio Caí permitindo o amortecimento de cheias de pequeno porte. Porém, o efeito observado no primeiro ponto de monitoramento fluviométrico da bacia (posto Nova Palmira) é atenuado pelo acréscimo de área de drenagem entre os reservatórios e o posto Nova Palmira, especialmente o efeito sobre as vazões máximas (COLLISCHONN et al., 2007). No ano de 2024 a BHRC passou pelo maior evento de cheia já registrado. Nesse evento, a cota do rio Caí no município de Passo Montenegro, onde a cota de inundação do rio Caí é de 6 metros, ultrapassou a cota de 9 metros (CPRM, 2024)e no município de São Sebastião do Caí, cuja cota de inundação é 10,50 metros, o rio Caí atingiu a cota de 17 metros (CEMADEN, 2024).

O regime hidrológico da bacia é caracterizado por precipitações bem distribuídas ao longo de todo ano, com máximos relativos nas estações de transição (REBOITA et al., 2010). Na vazão também é observado um regime bimodal com máximas nas estações de transição (figura 37).



Figura 37 – Modelo Digital de Elevação da Bacia Hidrográfica do Caí, postos fluviométricos utilizados e gráficos chuva-vazão ilustrativo do comportamento hidrológico da bacia.

Fonte: Elaborado pelo autor. Modelo digital de elevação SRTM (NASA, 2013), dados vazão medida disponíveis em ANA (2021) e dados de precipitação disponibilizados por Beck et al. (2019).

A tabela 14 apresenta estatísticas descritivas dos postos de vazão existentes na bacia que auxiliam na interpretação das características do regime hidrológico da bacia (NAGHETTINI; PINTO, 2007).

A razão Q10%/Q50% mostra que as vazões de cheia são entre 4 e 7,5 vezes maior que a mediana, os coeficientes de assimetria (S) e curtose (K) mostram que o histograma de frequências possui desvio positivo e distribuição leptocúrtica ("pontiaguda"). Em conjunto estes parâmetros mostram que a BHRC é a bacia de resposta mais rápida entre as analisadas. Bacias com estas características, quando comparadas com bacias de respostas gradual lenta, apresentam um desafio maior para previsão hidrológica de inundações de curto prazo.

Tabela 14 – Estatísticas descritivas do regime de vazão dos postos de monitoramento: vazão média (**Q**), desvio padrão (SD), coeficiente de variação, vazão com permanência de superação de 10%, e 95% (Q10% e Q95%, respectivamente), razão entre Q10% e Q50%, assimetria (S), curtose (K) e vazão máxima diária anual média (MDM).

Posto	Q	SD	CV	Q10%	Q95%	Q10%/Q50%	S	K	MDM
Linha Gonzaga	24,4	48,6	2,0	51,6	3,4	4,9	6,9	6,5	56,9
Nova Palmira	43,1	78,4	1,8	96,2	5,9	4,9	6,1	9,1	132,7
São Vendelino	6,2	14,1	2,3	16,2	0,3	8,0	7,5	1358,4	81,7
Barca do Caí	72,4	132,2	1,8	169,7	7,8	6,1	4,3	17,4	141,7
Costa do rio cadeia	18,5	29,7	1,6	44,8	1,4	6,5	3,5	32,3	341,9
Passo Montenegro	98,6	136,7	1,4	209,8	21,8	4,0	3,7	5,4	1027

Fonte: Elaborado pelo autor.

# 5.2 Pré-processamento do modelo hidrológico

Em função da disponibilidade de dados fluviométricos concomitantes em todas as estações de monitoramento da bacia, o modelo SWAT foi aplicado para a BHRC no período de 15/09/2015 a 31/12/2019. O período de 15/09/2015 até 31/12/2016 foi utilizado para a calibração do modelo e o restante do período (01/01/2017 a 31/12/2019) foi utilizado para a validação do modelo e posteriormente para a realização dos experimentos de previsão de vazão.

A figura 38 apresenta o resultado da geração das 116 minibacias e da rede de drenagem com o SWAT, localização espacial dos centros da grade de reanálise de vento, radiação e umidade e localização espacial dos centros da grade de chuva do MSWEP.

O SWAT resolve a precipitação na minibacia pelo método do vizinho mais próximo. Uma vez que a interpolação pelo inverso da distância tem se mostrado mais eficiente na representação do campo de precipitação em modelagem com o SWAT (SZCZEŚNIAK; PINIEWSKI, 2015) os dados de precipitação do MSWEP foram previamente interpolados para os centroides das minibacias.

Figura 38- Divisão em minibacias e representação da (a) centroides das minibacias, (b) centroides da grade reanálise, (c) rede de drenagem do SWAT, (d) centroides da grade de chuva observada e (e) centroides das previsões numéricas de chuva do ECMWF



Fonte: Elaborado pelo autor.

Durante o pré-processamento também é feita a delimitação das URH da bacia. No SWAT as URHs são definidas pelo cruzamento de informações de cobertura da superfície, tipo de solo e relevo. Neste trabalho foram utilizadas as informações de cobertura da superfície do Mapbiomas, sendo que as classes semelhantes foram agrupadas em uma mesma classe, conforme a tabela 15.

Classe Mapbiomas	Classe SWAT
Formação florestal	FRSE
Floresta plantada	FRSE
Campo alagado	WETN
Formação campestre	RNGE
Pastagem	PAST
Mosaico agricultura e pastagem	PAST
Infraestrutura Urbana	URML
Outras áreas não vegetadas	URML
Corpo d'água	WATER
Soja	PAST
Outras culturas	PAST

Tabela 15 – Reclassificação das classes de cobertura da superfície do Mapbiomas para as classes do banco de dados do SWAT

Fonte: Elaborado pelo autor.

A tabela 16 apresenta os valores iniciais dos parâmetros de superfície de solo que são relevantes para a geração de escoamento superficial. Para o caso dos usos denominados FRSE (floresta sempre verde) e PAST (áreas agrícolas) estes parâmetros se referem ao coeficiente de Manning para escoamento superficial (OV\_N) e o valor da curva número do SCS para condição de umidade II (CN2). Para o caso do uso denominado URHD (urbano de alta densidade), além dos parâmetros anteriores, incluise o valor da curva número do SCS para condição de umidade II em área urbana (URBCN2), fração da área urbana impermeável (FIMP) e a fração da área urbana impermeável interconectada (FCIMP).

Cohortura	OV N		CN	2							IA	F					
Cobertura	UV_N	Α	В	С	D	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
FRSE	0.10	25	55	70	77	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0	6.0
PAST	0.15	49	69	79	84	4.0	4.0	3.0	2.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	3.0
WETN	0.05	49	69	79	84	2.0	2.0	2.0	2.0	1.0	1.0	1.0	1.0	2.0	2.0	2.0	2.0
RNGE	0.15	49	69	79	84	3.0	3.0	2.0	2.0	1.5	1.5	1.5	1.5	2.0	2.0	2.0	3.0
						SCS Runoff Curve Numbers											
		UV_N			Α		В			С			D				
UKIVIL	0.1		-	31				59			72			79			
		URBO	CN2	F	IMP (f	ractio	n)	FCIMP (fraction)			)						
		98			0.	.2		0.17									

Tabela 16 - Valores iniciais dos parâmetros de superfície relevantes para geração de escoamento

Fonte: elaborado pelo autor

A tabela 17 apresenta os valores dos parâmetros de solo relevantes para geração de escoamento no modelo SWAT e adotados para iniciar a modelagem da bacia.

	<b>a</b> 1	Latossolo (LVAd)	Cambissolo	Planossolo	Neossolo	Nitossolo
Parametro	arametro Camada (Pereira, 2		(Rafee et al., 2019)	(Rafee et al., 2019)	(Rafee et al., 2019)	(Rafee et al., 2019)
NLAYERS		4	5	5	1	6
HYDGRP	não se	А	В	С	А	В
SOL_ZMX	aplica	1400	1100	1400	200	1800
ANION_EXCL		0.38	0.5	0.5	0.5	0.5
SOL_Z1		200	300	200	200	150
SOL_AWC1	1	0.23	0.18	0.24	255	0.21
SOL_K1		75	2	1	2.5	1.5
SOL_Z2		1400	600	400	660.4	400
SOL_AWC2	2	0.27	195	135	0.13	0.18
SOL_K2		33	0.5	0.2	110	0.3
SOL_Z3		1210	800	550	1524	650
SOL_AWC3	3	0.4	0.21	0.18	0.02	165
SOL_K3		12.5	0.7	0.2	550	0.3
SOL_Z4		1500	1000	680	0	950
SOL_AWC4	4	0.4	0.21	0.14	0	0.21
SOL_K4		12.5	0.7	8	0	0.1
SOL_Z5		0	1100	1400	0	1300
SOL_AWC5	5	0	0.14	0.14	0	0.14
SOL_K5		0	8	8	0	8
SOL_Z6		0	0	0	0	1800
SOL_AWC6	6	0	0	0	0	135
SOL_K6		0	0	0	0	0.06

Tabela 17 - Valores iniciais dos parâmetros de solo para geração de escoamento

Fonte: Elaborado pelo autor.

O relevo foi subdividido em duas classes, acima de 5% de declividade e abaixo de 5% de declividade. Esta subdivisão foi feita para permitir que o modelo aceite valores de CN diferentes para um mesmo tipo de combinação cobertura/solo com declividade diferente. Este ajuste é necessário uma vez que os valores de CN da base de dados do SWAT são para áreas com declividade de até 5% (NIETSCH et al., 2009).

Por fim, as classes de cobertura, tipo de solo e relevo (figura 39) que representam menos de 10% da área de uma minibacia são incorporadas à classe mais próxima da mesma minibacia. A figura 40 apresenta o resultado do cruzamento das classes de cobertura da superfície, classes de solo, classes de declividade do relevo que resultam em 35 URHs.



Figura 39- Classificação de cobertura (a), solos (b) e declividade (c) utilizada para cruzamento e geração das unidades de resposta hidrológica

Fonte: Elaborado pelo autor.



Figura 40 - Unidades de resposta hidrológica na bacia do Rio Caí

Fonte: Elaborado pelo autor.

# 5.3 Análise de sensibilidade, calibração e validação do modelo hidrológico para Bacia do Rio Caí

Após o pré-processamento foi realizada a análise de sensibilidade do modelo hidrológico para a bacia conforme descrito no item 3.1.3. A tabela 18 mostra o resultado do teste-t e o p-valor para os 20 parâmetros considerados na análise de sensibilidade. Em negrito, estão destacados os parâmetros cuja sensibilidade é estatisticamente significativa, sendo eles o CN2 (curva número do SCS para condição de umidade II), SOL\_K (condutividade hidráulica do solo), RCHRG\_DP (coeficiente de percolação), CH\_N2 (coeficiente de Manning do canal), GWQMN (limiar para recarga no canal principal), CANMX (máximo armazenamento de água no dossel) e LAT\_TTIME (tempo de percurso do escoamento lateral).

Parâmetro	teste-t	p-valor
CN2.mgt	25,4	<0,01%
SOL_K.sol	6,3	<0,01%
RCHRG_DP.gw	5,1	<0,01%
CH_N2.rte	-4,1	<0,01%
GWQMN.gw	-3,7	0,02%
CANMX.hru	-2,5	1,38%
LAT_TTIME.hru	-2,1	4,06%
EPCO.bsn	-1,9	5,3%
GW_REVAP.gw	-1,6	10,9%
OV_N.hru	-1,5	13,7%
SLSUBBSN.hru	-1,4	15,3%
ALPHA_BF.gw	1,1	26,7%
SURLAG.bsn	-0,9	37,2%
ALPHA_BNK.rte	-0,9	37,5%
ESCO.hru	0,8	40,1%
CH_K2.rte	-0,8	44,8%
GW_DELAY.gw	0,7	49,4%
SURLAG.hru	0,4	67,7%
REVAPMN.gw	0,4	72,6%
SOL_AWC.sol	-0,2	86,1%

Tabela 18 - Resultado da análise de sensibilidade dos parâmetros importantes para

representação da vazão na bacia do rio Caí

Deste modo, a calibração do modelo será iniciada considerando apenas os parâmetros cuja sensibilidade possui significância estatística e utilizando o intervalo de valores proposto para a análise de sensibilidade (tabela 19).

Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo
CN2.mgt	Relativa	-0.9	0.9
SOL_K.sol	Relativa	-0.9	0.9
RCHRG_DP.gw	Valor	0	1
CH_N2.rte	Valor	0.01	0.3
GWQMN.gw	Valor	0	5000
CANMX.hru	Valor	0	100
LAT_TTIME.hru	Valor	0	10

Tabela 19 – Parâmetros utilizados para calibração. Para o tipo de mudança Valor, o valor inicial é substituído por valores dentro do intervalo especificado e para mudança relativa o valor inicial é multiplicado por 1+ r, em que r é um valor no intervalo especificado.

A seleção do melhor conjunto de parâmetros foi feita considerando o melhor resultado da média da função objetivo em todos os pontos em que há observação disponível. Será mostrado neste capítulo apenas o resultado final dos melhores parâmetros, uma análise detalhada dos resultados em cada uma das rodadas de calibração é mostrada no anexo D.

Na estação Linha Gonzaga o coeficiente de Nash reduz na terceira rodada e em seguida volta para mesma faixa de valores das duas primeiras rodadas. Para estação Nova Palmira a variação é pequena entre as simulações, já no posto Costa R. Cadeia o coeficiente de Nash reduz da segunda rodada em diante. O inverso ocorre na estação Barca do Caí na qual o coeficiente de Nash aumenta a partir da segunda rodada. Para a estação Passo Montenegro a variação é pequena entre as simulações, com redução do coeficiente de Nash na segunda rodada.

A tabela 20 apresenta os valores dos coeficientes de avaliação para o período de calibração do modelo. De acordo com o coeficiente de Nash, o posto Nova Palmira tem o melhor desempenho no período de calibração, enquanto o posto Barca do Caí obteve o pior desempenho. Os hidrogramas e o gráfico de dispersão das vazões simuladas e observadas (Anexo E), mostra que nos postos Linha Gonzaga e Nova Palmira o modelo simula adequadamente as vazões baixas e intermediárias, enquanto as vazões altas são subestimadas.

Para os postos C. do Rio Cadeia, Barca do Caí e Passo Montenegro o modelo subestima as vazões de modo geral, ainda que consiga representar a variabilidade da bacia, o que também é evidenciado pelos valores de R nestas estações.

O resultado é semelhante para o período de validação (tabela 21), porém as variações dos coeficientes de avaliação indicam diminuição na capacidade de representação do modelo em alguns postos.

No posto Passo Linha Gonzaga a redução do coeficiente de Nash, KGE e R indicam piora no desempenho do modelo para o período de validação, enquanto que a redução do RMSE e erro absoluto são positivos para o desempenho do modelo. Para o posto Barca do Caí o os coeficientes de desempenho Nash, KGE, RMSE e EMA indicam melhora no desempenho do modelo para o período de validação enquanto que a redução do R indica o oposto. O resultado do coeficiente de Nash é melhor na estação Passo Montenegro os coeficientes KGE, RMSE e EMA também indicam melhora no desempenho do modelo em relação ao período de calibração e o oposto é indicado pela redução do R.

É conveniente destacar que o período de validação (1094 dias) é maior do que o período de calibração (473 dias) de modo que as reduções nos coeficientes também estão associadas ao tamanho amostral e não somente à deficiências do modelo em representar as vazões para este período. Também destaca-se que o período de calibração coincide com um período de chuva intensificado pela atuação do El Niño Oscilação Sul.

Tabela 20 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE), Erro Absoluto (EMA) e Erro Médio (EM) para o período de calibração (15/09/2015 a 31/12/2016)

Posto	NSE	KGE	R	RMSE	EMA	EM
Linha Gonzaga	0,64	0,60	0,66	36,08	19,03	8,64
Nova Palmira	0,67	0,64	0,69	56,34	21,09	-6,72
C. do Rio Caldeia	0,47	0,31	0,62	26,98	13,12	-12,51
Barca do Caí	0,45	0,22	0,71	135,65	56,36	-51,06
Passo Montenegro	0,55	0,34	0,79	120,09	68,05	-67,42

Fonte: Elaborado pelo autor.

			<i>,</i>			
Posto	NSE	KGE	R	RMSE	EMA	EM
Linha Gonzaga	0,24	0,37	0,39	28,28	16,92	9,95
Nova Palmira	0,48	0,52	0,48	50,34	22,9	-0,27
C. do Rio Caldeia	0,43	0,27	0,60	20,99	10,03	-9,4
Barca do Caí	0,48	0,36	0,59	90,74	37,4	-22,47
Passo Montenegro	0,51	0,43	0,63	86,8	46,61	-39,33

Tabela 21 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE), Erro Absoluto (absBIAS) e Erro médio (EM) para o período de validação (01/01/2017 a 31/12/2019)

Fonte: Elaborado pelo autor.

O modelo apresenta limitações para representar as vazões em todos os postos da bacia. O resultado da calibração foi melhor para a estação Linha Gonzaga enquanto que para validação o resultado demanda interpretação mais cuidadosa dos hidrogramas e gráficos de dispersão associados com os resultados dos coeficientes de avaliação. Os coeficientes de avaliação indicam melhor desempenho no posto Passo Montenegro, contudo, a análise gráfica dos hidrogramas (Anexo D) ainda mostra desempenho satisfatório para os postos Linha Gonzaga e Nova Palmira.

#### 5.4 Previsões numéricas de precipitação

Este item trata da avaliação das previsões de precipitação da BHRC. É apresentada tanto a avaliação das previsões quantitativas de precipitação do ECMWF (também denominada de previsões brutas) quanto à avaliação das previsões processadas para geração de previsões probabilísticas. O capítulo apresenta primeiramente o resultado da definição da janela de processamento seguido da avaliação das previsões brutas e processadas e as conclusões do capítulo.

#### 5.4.1 Processamento das previsões numéricas de precipitação da BHRC

A figura 41 mostra a evolução do  $\overline{CRPS}$ , para todo o período de análise, utilizando janelas móveis de 60 até 200 dias para as três técnicas de processamento propostas, nos horizontes de tempo de 24 h a 120 h.

O resultado é diverso de acordo com a técnica de processamento utilizada. Para o processamento com a BMA no horizonte de 24 horas nota-se que o valor de  $\overline{CRPS}$  diminui em função do aumento do tamanho da janela até a janela de 150 dias quando se

estabiliza. Para os demais horizontes de previsão, o processamento com a BMA não gera resultados em que é possível definir com clareza uma janela de corte. No horizonte de 48 h o  $\overline{CRPS}$  oscila, porém sem haver uma tendência de redução ou aumento em função do tamanho da janela. Um resultado semelhante é obtido para o horizonte de 72 h e 120 h enquanto que para 96 h é observada tendência de aumento do CRPS com o aumento da janela de previsão. Ainda assim destaca-se que a variação do  $\overline{CRPS}$  é pequena, sendo a maior amplitude de variação de 0,5 (observada no horizonte de 96 h).

Para o processamento com CSG e GEV o padrão de variação do  $\overline{CRPS}$  em função do tamanho da janela utilizada é bem semelhante. Os valores oscilam com tendência de aumento que se acentua a partir da janela de 160 dias aproximadamente. Convém destacar que tanto para o processamento com o modelo CSG quanto GEV, a amplitude de variação do  $\overline{CRPS}$  é bem menor do que aquela observada com o modelo BMA.

Pode-se definir que para o processamento com a BMA é importante que a janela seja maior ou igual a 150 dias, de modo a garantir um bom desempenho no horizonte de 24 h, nos horizontes de 48 h, 72 h e 120 h a constância no  $\overline{CRPS}$  em função da janela mostra que há pouca dependência da escolha da janela para otimização do desempenho do modelo e para o horizonte de 96 h a melhor janela seria entre 60 e 100 dias, porém, as janelas entre 100 e 150 dias também não representam o pior cenário. Para os modelos CSG e GEV janelas entre 50 e 160 dias garantem  $\overline{CRPS}$  baixo. Deste modo, foi selecionada a janela de 150 dias para o processamento das previsões.

Figura 41 – *Continous Rank Probability* (CRPS) em função do tamanho da janela de treinamento (em dias) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna) e para os diferentes modelos probabilísticos (um modelo em cada linha, com cores diferentes)



Fonte: Elaborado pelo autor.

Uma vez definido o tamanho da janela de treinamento, foi feita a avaliação das previsões probabilísticas. A figura 42 apresenta os resultados dos coeficientes determinísticos utilizados para avaliação da qualidade das previsões. Para o ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de superação de 50% como referência de previsão determinística.

O coeficiente R apresentou valores baixos e em alguns casos negativos, de acordo com o horizonte de tempo e o método utilizado. Para o EM, a média do ECMWF apresenta resultado mais próximo de zero e com viés negativo, enquanto que as previsões processadas apresentam viés positivo de magnitude maior do que a previsão bruta. Para o coeficiente EMA, as previsões processadas apresentaram o melhor resultado. Figura 42 – Coeficientes determinísticos para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja). Para o ECMWF foi utilizada a média dos 51 membros e para as previsões processadas o percentil de superação de 50% como referência de previsão determinística



Fonte: Elaborado pelo autor.

O Brier Score foi calculado considerando diferentes limiares de precipitação (figura 43). Independente do limiar utilizado, o desempenho das previsões brutas do ECMWF apresentou o pior desempenho. Para o limiar de 0,1 mm, o desempenho das previsões processadas com o modelo BMA apresentou melhores resultados no horizonte de 24 h seguido pelos modelos CSG e GEV, para o limiar de 5 mm os modelos GEV e CSG apresentaram resultados semelhantes e que indicam o melhor desempenho, seguido pelo modelo BMA. O padrão anterior é observado também para os limiares de 10 mm e 15 mm.

Analisando o padrão dos gráficos em função do horizonte de tempo, nota-se que, independente do método de previsão utilizado, o desempenho das previsões melhora em função do aumento do horizonte de previsão para as previsões brutas. Conforme será mostrado a seguir, as previsões brutas apresentam padrão de concentração dos membros e, à medida que o horizonte de previsão é ampliado, as trajetórias das previsões tendem a se espalhar mais. Fato que pode ter contribuído para melhora do BS em função do horizonte de previsão. Figura 43 – Brier Score para as previsões por conjunto do ECMWF (preto) e processadas com os modelos probabilísticos BMA (azul), GEV (verde) e CSG (laranja) utilizando os limiares de 0,1 mm, 5 mm, 10 mm e 15 mm para discriminação de eventos.



Fonte: elaborado pelo autor

Para as previsões quantitativas de precipitação do ECMWF, os *rank histograms* de todos os horizontes de tempo apresentam formato de "U" (figura 44). Este padrão de dispersão indica que as observações ocupam com maior frequência as posições extremas na distribuição, ou seja, os membros do conjunto possuem pouco espalhamento. À medida que o horizonte de previsão se amplia, o padrão de dispersão apresenta discreta atenuação.



Figura 44 - *Rank Histogram* para previsões de precipitação da BHPS para horizontes de previsão de 24 h a 120 h. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.

Para permitir a comparação entre os *rank histograms* das previsões brutas com os PIT *histograms* das previsões processadas, foi utilizado o mesmo número de classes (10). A figura 45 apresenta o resultado para a chuva processada com os três modelos probabilísticos propostos.

Para o modelo BMA, nota-se que os histogramas apresentam ainda um padrão do tipo "U", porém com melhora no padrão de dispersão. Este padrão é semelhante em todos os horizontes de tempo. Para o caso das previsões processadas com o modelo GEV, os histogramas apresentam padrão tipo U, porém com padrão de dispersão melhor em relação ao modelo anterior e às previsões brutas do ECMWF. O processamento com o modelo CSG apresenta o comportamento mais próximo do ideal, no qual os membros seriam equiprováveis. Comparando o resultado do modelo CSG com os demais modelos e com a previsão bruta, este apresentou o melhor resultado em termos de dispersão dos membros do conjunto.

Figura 45 – Probability Integral Transform histogram (PIT) dos modelos BMA (azul), GEV (verde) e CSG (laranja) para previsões com horizontes de 24 h a 120 h (um horizonte em cada coluna). A linha horizontal tracejada indica o comportamento desejado do gráfico de barras, no qual todas as probabilidades possuem a mesma frequência relativa



Fonte: Elaborado pelo autor.

Entre a figura 46 e a figura 49 estão apresentados os diagramas de confiabilidade da previsão bruta do ECMWF e das previsões processadas, para diferentes limiares de precipitação. Tanto para as previsões brutas do ECMWF quando para as previsões processadas, os diagramas não indicam comportamento satisfatório e na maior parte dos casos apresenta comportamento errático ou de baixa resolução.

Figura 46 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 0,1 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento



Fonte: Elaborado pelo autor.

Figura 47 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 5 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento



Fonte: Elaborado pelo autor.

Figura 48 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 10 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado



Fonte: Elaborado pelo autor.

Figura 49 – Diagrama de Confiabilidade (*Reliability Diagram*) para chuvas acima de 15 mm. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado



Fonte: Elaborado pelo autor.

A figura 50 apresenta as curvas ROC para diferentes limiares de chuva. De modo geral, o comportamento tanto da previsão bruta do ECMWF, quanto das previsões processadas com os modelos probabilísticos é semelhante entre si, sendo que a capacidade de detecção das previsões é igual ou pior ao uso da climatologia como referência para previsão.

Figura 50 – Curva ROC para chuvas acima de 0,1 mm, 5 mm, 10 mm e 15 mm, para previsões com horizontes de 24 h a 120 h. A curva apresenta no eixo X a probabilidade de alarme falso e no eixo Y a probabilidade de detecção do evento, sendo representado conjuntamente a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A reta identidade indica a climatologia e a curva ideal deve ficar acima e o mais distante possível da identidade



### 5.5 Previsões de vazão na BHRC

Neste item são apresentados os resultados das previsões de vazão realizadas para a BHRC. As previsões de vazão foram realizadas continuamente (dia a dia) no período de 21/03/2018 até 17/10/2019 (575 dias), definido conforme a disponibilidade de previsões contínuas, para os horizontes de previsão de 24 h a 120 h (5 horizontes de tempo), com o modelo hidrológico alimentado tanto com a previsão controle quanto com os membros perturbados do ECMWF (50 membros perturbados + 1 membro controle), além dos quantis de probabilidade das previsões processadas com cada um dos modelos probabilísticos utilizados (10 membros em cada modelo probabilístico).

Inicialmente é feita a comparação entre as vazões de saída ajustada e sem ajuste geradas a partir das previsões de precipitação brutas do ECMWF. Nos itens seguintes são mostrados os resultados para previsão de vazão gerada tanto com previsões brutas do ECMWF quanto com os quantis das previsões processadas e com a vazão de saída sem ajuste e ajustada.

### 5.5.1 Comparação entre a previsão ajustada e sem ajuste

A figura 51 apresenta o erro percentual da previsão de 24 h a 120 h para os postos fluviométricos da bacia, com o modelo hidrológico alimentado com as previsões brutas do ECMWF. A previsão sem ajuste se refere à vazão de saída do modelo e a previsão ajustada corresponde às previsões após a aplicação do ajuste proposto no item 3.3.1 deste trabalho.

Para estação Barca do Caí, o ajuste proposto não representa redução considerável do erro da previsão, para os horizontes de 24 h a 72 h. Já nos horizontes de 96 h e 120 h há uma tendência superestimativa das previsões que é corrigida nas previsões ajustadas. As previsões sem ajuste do posto C. do rio Cadeia apresentam viés negativo em todos os horizontes de previsão. O ajuste proposto melhora o viés nos três primeiros horizontes de previsão (24 h a 96 h), nos demais horizontes o ajuste proposto não representa melhora no viés. O posto Linha do Gonzaga apresenta previsões com viés positivo nas previsões sem ajuste. Enquanto que as previsões ajustadas apresentam erro mais próximo de zero. Resultado semelhante ao anterior é observado na estação Nova Palmira. Por fim, o ajuste proposto melhora o viés das previsões do posto Passo Montenegro, que apresenta viés negativo nas previsões sem ajuste.



Figura 51 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste para os postos de monitoramento fluviométrico da bacia do rio Caí (linhas) para horizontes de previsão de 24 h a 120 h (colunas). O gradiente de cores indica o percentil das amostras associadas ao erro encontrado.

Fonte: Elaborado pelo autor.

Conforme pode ser visto na figura 52, que apresenta o erro percentual por trimestre para a estação Passo Montenegro. É possível verificar que o ajuste proposto corrige o viés negativo das previsões sem ajuste. No trimestre DJF a diferença entre a previsão sem ajuste e ajustada é mais destacada. Para o horizonte de 24 h todos os membros das previsões apresentavam viés negativo enquanto que na previsão ajustada, ainda que com maior variabilidade, a mediana do erro da previsão fica mais próxima de zero. O mesmo é observado para os horizontes de previsão seguintes (48 h a 120 h), contudo, com maior espalhamento do erro percentual.

O resultado é semelhante para os demais trimestres, que apresentam o mesmo padrão de viés negativo na previsão sem ajuste e com a mediana do erro mais próxima de zero para as previsões ajustadas. Para o trimestre SON o ajuste proposto melhora a qualidade em relação às previsões sem ajuste, porém, mesmo nas previsões ajustadas a mediana do erro é negativa em todos os horizontes de previsão. Figura 52 – Erro percentual da vazão simulada para previsão ajustada e sem ajuste do posto de monitoramento fluviométrico Passo Montenegro para horizontes de previsão de 24 h a 120 h (linhas) separados de acordo com trimestres (colunas) DJF (dezembro- janeiro – fevereiro), MAM (março – abril – maio), JJA (junho- julho- agosto) e SON (setembro – outubro – novembro). O gradiente de cores indica o percentil das amostras associadas ao erro encontrado



Fonte: Elaborado pelo autor.

### 5.5.2 Comparação entre as previsões de vazão bruta e probabilísticas

Os resultados de comparação entre as previsões de vazão bruta e probabilística mostrados neste item se referem ao posto Passo Montenegro (Figura 53), que é o posto mais a jusante da bacia e representa o comportamento médio do escoamento da bacia a montante do posto. A análise detalhada dos demais postos de monitoramento fluviométrico é mostrada no Anexo D.

Um ponto que se destaca é que as previsões probabilísticas apresentam comportamento muito semelhante entre si. Isto ocorre, pois, conforme definido na metodologia, para as previsões probabilísticas foi utilizado o percentil 50% como referência de previsão determinística e as FDPs parametrizadas não apresentam diferenças significativas nos percentis mais baixos.

As previsões brutas do ECMWF sem ajuste da vazão de saída não apresentam correlação com a vazão observada, em todos os horizontes de previsão analisados. As previsões probabilísticas sem ajuste da vazão de saída a correlação vão de 0,81 a 0,38 entre o horizonte de previsão de 24 h e 120 h.

Para as previsões brutas do ECMWF com a vazão de saída ajustada, a correlação é melhor do que a obtida utilizando a previsão bruta do ECMWF e sem ajuste da vazão de saída, sendo a variação da correlação de 0,40 a 0,06 entre os horizontes de 24 h e 120 h. As previsões processadas com a vazão de saída ajustada apresentaram o melhor resultado entre todos os métodos testados. As correlações de 24 h, 48 h e 120 h para o posto Passo Montenegro são 0,87, 0,89, e 0,87, respectivamente.

Com relação às previsões de vazão sem ajuste geradas com a previsão de precipitação bruta do ECMWF, o EMA aumenta em função do horizonte de previsão. No posto Passo Montenegro o EMA é de 55  $m^3 s^{-1}$  para o horizonte de 24 h e aumenta para 67  $m^3 s^{-1}$  no horizonte de 120 h. Para as previsões probabilísticas sem ajuste da vazão de saída o resultado é melhor do que o anterior. A variação do EMA é de 48  $m^3 s^{-1}$  a 67  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h.

Para as previsões com ajuste da vazão de saída geradas com a previsão de precipitação bruta do ECMWF o EMA é melhor do que no caso sem ajuste de saída. De modo geral há um aumento mais acentuado entre os horizontes de 24 h e 48 h, seguido de aumento suave entre 48 h e 120 h. A variação no posto Passo Montenegro vai de 48  $m^3s^{-1}$  no horizonte de 24 h, chega a 65  $m^3s^{-1}$  no horizonte de 48 h e no horizonte de 120 h o EMA é de 82  $m^3s^{-1}$ . As previsões processadas com a vazão de saída ajustada

Com relação às previsões de vazão sem ajuste geradas com a previsão de precipitação bruta do ECMWF, o EM se afasta de zero em função do horizonte de previsão. O valor de EM reduz entre os horizontes de 24 h e 120 h passando de 48  $m^3 s^{-1}$  para 31  $m^3 s^{-1}$ . Para as previsões processadas sem ajuste da vazão de saída, o EM aumenta de 45  $m^3 s^{-1}$  para 63  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h.

Para as previsões com ajuste da vazão de saída geradas com a previsão de precipitação bruta do ECMWF o EM no horizonte de 24 h é 15  $m^3 s^{-1}$  e reduz nos horizontes seguintes, chegando a -5  $m^3 s^{-1}$  no horizonte de 120 h. As previsões processadas com a vazão de saída ajustada apresentam aumento em função do horizonte de previsão, passando de 5  $m^3 s^{-1}$  para 40  $m^3 s^{-1}$  entre os horizontes entre de 24 h e 120 h.

Figura 53 – Coeficiente de correlação (R), Erro Médio Absoluto (EMA) e Erro Médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste para o posto Passo Montenegro



Fonte: Elaborado pelo autor.

A figura 54 apresenta o resultado do BS, considerando como limiar de cheia o percentil 75% da vazão, e do CRPS tanto para previsões geradas a partir dos quantis de precipitação quanto para as previsões brutas do ECMWF e considerando a vazão sem ajuste e ajustada.

Primeiramente serão analisadas as previsões geradas utilizando as previsões de precipitação brutas do ECMWF sem ajuste da vazão de saída. A variação do BS em função do horizonte de previsão é baixa, variando entre 0,22 e 0,20 entre os horizontes de 24 h e 120 h. Para as previsões processadas sem ajuste da vazão de saída, o BS também apresenta pouca variação em função do horizonte de previsão. Para o posto Passo Montenegro o BS para previsões processadas com os modelos GEV e CSG varia entre 0,17 e 0,20 e para o processamento com modelo BMA varia entre 0,18 e 0,24 em ambos os casos entre os horizontes de 24 h e 120 h.

As previsões geradas utilizando as previsões de precipitação brutas do ECMWF com ajuste da vazão de saída apresentam aumento do BS em função do horizonte de previsão, passando de 0,18 no horizonte de 24 h para 0,33 no horizonte de 120 h. Para as previsões de precipitação processadas e com a vazão de saída ajustada, o comportamento dos modelos é muito semelhante sendo que o modelo BMA apresenta resultado inferior (BS mais alto) do que os modelos GEV e CSG. Entre os horizontes de 24 h e 48 h, o BS passa de 0,15 para 0,17 e em seguida reduz para 0,12 para os modelos GEV e CSG. Para o modelo BMA o BS passa de 0,16 para 0,19 entre 24 h e 48 h e reduz para 0,15 nos horizontes seguintes.

Para as previsões geradas utilizando as previsões de precipitação brutas do ECMWF sem ajuste da vazão de saída, o comportamento do CRPS é semelhante tanto entre os diferentes tipos de previsões quanto em termos de evolução do coeficiente ao longo dos horizontes de previsões, aumentando de 54  $m^3s^{-1}$  no horizonte de 24 h para 58  $m^3s^{-1}$  no horizonte de 120 h. Para as previsões de precipitação processadas e com a vazão de saída sem ajuste, o CRPS possui aumento mais pronunciado em função do horizonte de previsão, sendo que no horizonte de 24 h é de 37  $m^3s^{-1}$  e aumenta até 56  $m^3s^{-1}$  no horizonte de 120 h.

As previsões geradas utilizando as previsões de precipitação brutas do ECMWF com ajuste da vazão de saída apresentam diferenças em relação ao observado quando não é feito o ajuste da vazão de saída. O resultado mostra aumento em função do horizonte de previsão, saindo de 41  $m^3 s^{-1}$  no horizonte de 24 h e chegando a 67  $m^3 s^{-1}$  no horizonte de 120 h. As previsões geradas a partir de previsões de precipitação

processadas e com a vazão de saída ajustada apresentam comportamento semelhante entre os modelos. O CRPS para o horizonte de 24 h é 27  $m^3 s^{-1}$ , reduz para 22  $m^3 s^{-1}$  no horizonte de 48 h e aumenta para 30  $m^3 s^{-1}$  no horizonte de 120 h.

Figura 54 – *Brier Score* (BS) considerando como limiar de cheia o percentil 75% da vazão e *Continous Ranked Probability Score* (CRPS), entre vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste, para o posto Passo Montenegro.



Fonte: Elaborado pelo autor.

A curva ROC para previsões de vazão é mostrada na figura 55. De acordo com o gráfico as previsões de vazão sem ajuste da vazão de saída geradas a partir da previsão de precipitação bruta do ECMWF possui a pior capacidade de discriminação de eventos. O ajuste da vazão de saída isoladamente promove alguma melhora na capacidade de discriminação. Da mesma forma, o processamento da previsão de precipitação com os modelos BMA, GEV e CSG também melhoram a capacidade de discriminação de eventos, sendo que os modelos GEV e CSG se destacam mais do que o modelo BMA. Contudo o melhor desempenho ocorre quando as previsões de precipitação são processadas com um dos modelos propostos e a vazão de saída do modelo hidrológico é ajustada, ou seja, a combinação do processamento da precipitação associada com o ajuste do modelo apresenta a melhor capacidade de discriminação de eventos.

Figura 55 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às previsões sem ajuste da vazão (ajustada)



Fonte: Elaborado pelo autor.

Os gráficos da figura 56 apresentam o diagrama de confiabilidade da previsão de vazão utilizando a precipitação bruta do ECMWF e com os quantis de precipitação dos modelos probabilísticos BMA, GEV e CSG. Em ambos os casos é apresentada apenas a modelagem com a vazão de saída ajustada e considerando o percentil 75% da vazão como limiar para ocorrência de eventos. O resultado para as vazões sem ajustes são, em todas as condições, piores do que com as vazões ajustadas e por brevidade as figuras foram omitidas.

Os resultados para a BHRC mostram comportamento irregular. Este tipo de comportamento está associado com a concentração excessiva dos membros do conjunto, no qual a previsão se comporta de modo similar a uma previsão determinística e o resultado é afetado pela concentração das amostras nas classes extremas.

Figura 56 – Diagrama de Confiabilidade (*Reliability Diagram*) da estação Ponte Alta I utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado



Fonte: Elaborado pelo autor.

Os *rank histograms* para a previsão de vazão gerada com o modelo hidrológico alimentado com as previsões brutas do ECMWF para horizontes de previsão de 24 h a 120 h, são apresentados na figura 57. Para as previsões sem processamento, os *rank histograms* de todos os horizontes de tempo apresentam formato de "U". Este tipo de formato indica concentração excessiva dos membros do conjunto, pois as observações se posicionam frequentemente nas classes extremas do histograma. A concentração excessiva implica em excesso de confiança na previsão, cujos membros indicam valores semelhantes entre si. O resultado segue o mesmo padrão em todas as estações de monitoramento da bacia e em todos os horizontes de tempo de previsão.


Figura 57 - Rank Histogram para previsões de vazão da BHRC para diferentes horizontes de tempo. A



Quantis Fonte: Elaborado pelo autor.

0.0

Para permitir a comparação entre os rank histograms das previsões brutas com os PIT histograms das previsões processadas, foi utilizado o mesmo número de classes (10). A figura 58 apresenta o resultado para a vazão previsão com o modelo hidrológico alimentado com a chuva processada utilizando os modelos BMA, GEV e CSG. Para as previsões geradas com o modelo BMA, o histograma apresenta um padrão em que as observações se concentram nos percentis mais altos, indicando assim que as previsões subestimam a vazão observada.

O resultado com os modelos GEV e CSG apresentam comportamento semelhante entre si. Neste padrão há uma concentração de observações na primeira classe, indicando que há um número de casos em que as observações são menores que a menor previsão, combinado com um padrão de observações se posicionando majoritariamente entre a probabilidade intermediária à alta. O resultado do PIT histogram está longe do padrão ideal, contudo, comparando com as previsões brutas do ECMWF, há melhora na qualidade da previsão de vazão (especificamente na dispersão dos membros do conjunto) utilizando a precipitação processada com o modelo GEV e CSG. Para as previsões com horizonte de 24 h as observações se concentram no primeiro percentil, ou seja, as observações são frequentemente menores que a previsão e nas três classes mais altas indicando que parte das observações estão frequentemente posicionadas entre os percentis mais altos. Este gráfico indica que o processamento com a GEV e CSG promoveu alguma melhora na distribuição das previsões, contudo, as previsões com os modelos GEV e CSG, assim como as previsões sem processamento, apresentam concentração dos membros.

Figura 58 – PIT *histogram* para previsões de precipitação processadas da BHRC em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.



Fonte: Elaborado pelo autor.

### 5.5.3 Hidrogramas de previsão da vazão máxima registrada

A tabela 22 apresenta a data e a vazão registrada na máxima em cada posto fluviométrico utilizado. Neste caso, o dia da vazão máxima é próximo para os postos Linha Gonzaga, Costa do Rio Cadeia e Passo Montenegro indicando que a vazão máxima está associada ao mesmo evento de precipitação nestes casos. Neste item é mostrado o resultado para o posto Passo Montenegro sendo a análise completa de todos os postos da bacia apresentada no anexo D.

Posto de monitoramento	Data da máxima	Vazão registrada ( $m^3 s^{-1}$ )
Linha Gonzaga	04/09/2018	219,0
Nova Palmira	04/05/2019	501,8
Costa do Rio Cadeia	02/09/2018	172,4
Barca do Caí	25/08/2018	764,9
Passo Montenegro	05/09/2018	746,1

Tabela 22 – Data e valor da vazão máxima registrada no período de estudo em cada posto de monitoramento

Fonte: Elaborado pelo autor.

Os hidrogramas de previsão do posto Passo Montenegro são mostrados na figura 59. Para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF sem ajuste e com ajuste da vazão de saída, há concentração dos membros do conjunto, sendo que apenas um membro se diferencia dos demais membros. Em nenhum caso a previsão consegue representar as vazões previstas.

Para o caso das previsões alimentadas com as previsões processadas com o modelo BMA, a previsão sem ajuste não representa nenhuma capacidade de previsão. Para a previsão com ajuste da vazão de saída a vazão prevista ainda subestima a observada e mesmo com o ajuste proposto, a previsão não representa a tendência da vazão observada.

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída mostra melhora no espalhamento em relação às previsões brutas do ECMWF, porém, sem capacidade de representar o hidrograma observado. O ajuste da vazão de saída mostra ganho em relação à vazão sem ajuste. Para os horizontes de 24 h a 72 h a vazão observada fica entre os quantis de 85% e 95%, no horizonte de 48 h a vazão observada fica entre os quantis de 55% e 65% e para as previsões com 96 h e 120 h de antecedência a vazão observada fica entre os quantis 75% e 85%.

Para as previsões processadas com o modelo CSG o resultado é semelhante ao anterior. Para a previsão sem ajuste da vazão de saída todos os quantis de previsão ficam abaixo da vazão observada. O ajuste da vazão de saída melhora o espalhamento em relação à vazão sem ajuste. Para o horizonte de 24 h e 48 h a vazão observada no pico fica entre os quantis de 85% e 95%, no horizonte de 72 h a vazão observada fica entre os quantis de 75% e 85%, para as previsões com 96 h e 120 h de antecedência, a vazão observada fica entre os quantis 75% e 85%.

Figura 59 – Hidrogramas de previsão da vazão máxima diária do período de estudo para o posto Passo Montenegro. A linha tracejada horizontal indica o dia do evento e a linha tracejada em vermelho a vazão observada.



Fonte: Elaborado pelo autor.

### 5.6 Resumo e conclusões do capítulo

Neste capítulo foi apresentada a caracterização fisiográfica da BHRC, os resultados da modelagem hidrológica, a avaliação da previsão de chuva para bacia (bruta e processada) e os resultados da previsão de vazão para a bacia. A bacia se divide, do mais declivoso para o mais plano, em três trechos: alto, médio e baixo Caí. Mais da metade da bacia é coberta por área florestal e se destacam ainda o uso agrícola e a formação campestre. O regime hidrológico da bacia é caracterizado por precipitações bem distribuídas ao longo de todo ano, com máximos relativos nas estações de transição. Na vazão também é observado um regime bimodal com máximas nas estações de transição.

Foram verificados quais dos parâmetros de calibração do SWAT são estatisticamente sensíveis para o processo de transformação de chuva em vazão, sendo que seis destes estão diretamente relacionados com a geração de escoamento (CN2, SOL\_K, RCHRG\_DP, CH\_N2, GWQMN, LAT\_TIME) e um atua de forma indireta (CANMX) na geração de escoamento.

O resultado da calibração e verificação foi realizado utilizando os coeficientes NSE, KGE, R, RMSE, EMA e EM, além dos gráficos de dispersão e dos hidrogramas simulado e observado da bacia. O resultado da calibração foi melhor para a estação Nova Palmira e Linha Gonzaga. Para o período de validação, os coeficientes indicam melhor desempenho do posto Passo Montenegro, contudo a análise gráfica dos hidrogramas ainda mostra desempenho satisfatório para os postos Linha Gonzaga e Nova Palmira.

O processamento da previsão de precipitação para a bacia foi realizado utilizando a janela de treinamento de 160 dias, definida de acordo com a variação do  $\overline{CRPS}$  em função da janela de treinamento utilizada no processamento da precipitação. As métricas determinísticas não indicam melhora relevante no desempenho das previsões processadas em relação às previsões brutas do ECMWF.

O BS indica, em todos os limiares testados, melhor desempenho das previsões processadas em relação à previsão bruta do ECMWF, sendo que a BMA obteve o melhor desempenho para o caso de chuva > 0,1 mm e nos demais limiares o processamento com a GEV e CSG foram melhores. O processamento com a GEV e CSG também melhorou o espalhamento das previsões que apresentavam concentração dos membros nas previsões brutas. A respeito da confiabilidade, o diagrama de

confiabilidade de todos os limiares apresentou comportamento errático ou baixa resolução, tanto para as previsões brutas do ECMWF, quanto para as previsões processadas. A curva ROC também não apresentou resultados aceitáveis.

Os coeficientes determinísticos para as previsões de vazão mostra que o processamento da previsão e o ajuste da vazão de saída melhoram o coeficiente R, o comportamento para o EMA segue o mesmo padrão indicando que o uso da previsão de chuva processada combinado com ajuste da vazão de saída apresenta melhor desempenho. Avaliando o EM as previsões brutas do ECMWF possuem desempenho melhor que as previsões processadas tanto sem ajuste da vazão de saída quando com a vazão de saída ajustada.

O resultado do BS foi calculado utilizando o percentil de 75% como limiar para detecção dos eventos. A diferença de desempenho é menor entre as previsões brutas e processadas quando a vazão de saída é ajustada, contudo o melhor desempenho ainda é das previsões de chuva processadas combinado com ajuste da vazão de saída, com destaque para o ajuste com a GEV e CSG.

Os resultados do CRPS mostram que as previsões com chuva processada combinado com ajuste da vazão de saída possuem o melhor desempenho.

A curva ROC também evidencia que o processamento da precipitação beneficiou a capacidade de detecção de eventos, tanto com a vazão de saída sem ajuste quanto com a vazão de saída ajustada, quando comparadas com a previsão de vazão gerada a partir das previsões brutas do ECMWF. A previsão com a vazão de saída ajustada gerada com a chuva processada apresentaram as curvas mais próximas do comportamento ideal, principalmente o modelo BMA.

A confiabilidade das previsões de vazão, indicada pelo diagrama de confiabilidade (neste caso elaborado considerando o percentil 75% da vazão como limiar para ocorrência de eventos), mostra comportamento muito irregular. Este tipo de comportamento está associado com a concentração excessiva dos membros do conjunto.

Em termos de espalhamento dos membros, o processamento da precipitação faz com que as previsões passem de um padrão em "U" (indicando concentração dos membros do conjunto) para um padrão concentrado nos quantis maiores que indica viés seco das previsões processadas.

A análise dos hidrogramas da máxima mostra que o ajuste da vazão de saída melhora a qualidade das previsões quando o modelo hidrológico é alimentado com os quantis de probabilidade das previsões processadas. O processamento com a BMA promove alguma melhora na previsão, porém, os quantis de probabilidade estão muito próximos de modo que não é possível distinguir os quantis nos hidrogramas de previsão. Ou seja, os quantis de probabilidade estão muito concentrados em torno do mesmo valor, o que explica o fato de que o processamento com a BMA melhora as estatísticas descritivas mas é penalizado nas estatísticas que consideram o espalhamento dos membros. Por sua vez, os processamentos com a GEV e com CSG mostram melhora no espalhamento dos quantis, que na maior parte dos casos (maioria dos postos fluviométricos e horizontes de previsão), formam um hidrograma de previsão que somente os quantis maiores envolvem o hidrograma observado, entre os modelos GEV e CSG, o segundo é o que apresenta o melhor desempenho.

### CONCLUSÕES

O objetivo deste trabalho foi testar se o desempenho das previsões hidrológicas por conjunto pode ser melhorado com a aplicação de técnicas de processamento das previsões numéricas de precipitação. Para cumprir esse objetivo, primeiramente foi implementado o modelo hidrológico SWAT para representação dos processos hidrológicos, posteriormente as previsões numéricas de precipitação foram processadas utilizando os métodos *Ensemble Model Output Statistics* e *Bayesian Model Average*. Para o *Ensemble Model Output Statistics* duas FDPs, foram testadas: a Generalizada de Valores Extremos e a função Gama, para horizontes de previsão de 24 h, 48 h, 72 h, 96 h e 120 h. As previsões de chuva processadas foram comparadas com as previsões brutas do ECMWF. Na etapa seguinte foram realizados experimentos de previsão hidrológica utilizando previsões numéricas de precipitação sem processamento e processadas para horizontes de previsão de 24 h, 48 h, 72 h, 96 h e 120 h, sendo o resultado das previsões hidrológicas alimentadas com previsões processadas comparado com o desempenho das previsões brutas do ECMWF.

Em função de um viés sistemático do modelo hidrológico foi proposta uma metodologia de ajuste da vazão prevista, baseada na última observação disponível, e da variação de vazão indicada pelas previsões hidrológicas. Deste modo, tanto para as previsões brutas do ECMWF, quanto para as previsões processadas, foi avaliado o desempenho das previsões hidrológicas sem ajuste e com ajuste da vazão de saída.

Este estudo foi realizado em duas bacias hidrográficas diferentes: a bacia hidrográfica do rio Paraíba do Sul (BHPS) e a bacia hidrográfica do rio Caí (BHRC).

A respeito da modelagem hidrológica, foi utilizado o algoritmo SUFI-2 para análise de sensibilidade e posterior calibração do modelo SWAT. Nas duas bacias os parâmetros CN2, LAT\_TIME e CANMX aparecem como parâmetros sensíveis na calibração do modelo. O parâmetro CN2 é uma abstração da capacidade de infiltração da URH que controla diretamente a geração de escoamento superficial e por este motivo se destaca na análise de sensibilidade. O CANMX controla o armazenamento de água máximo do dossel. O índice de área foliar é configurado no SWAT e não é calibrável, deste modo, o CANMX aparece como uma maneira de contornar a limitação de representar a interceptação da vegetação. O LAT\_TIME controla o tempo de percurso do escoamento lateral. Ambas as bacias compartilham de fração importante da sua área de drenagem com relevo com alta declividade, condição na qual o escoamento lateral é mais relevante na composição do escoamento total.

Somente na BHPS o parâmetro ESCO, que controla a evaporação de água do solo, obteve significância estatística no teste de sensibilidade. Neste caso a função do parâmetro é regular a fração de água evaporada da bacia.

A BHRC foi a única bacia em que o parâmetro de rugosidade do canal CH\_N2 se mostrou sensível na calibração. O SWAT realiza a propagação do escoamento no canal utilizando o método de Muskingum (NIETSCH et al., 2009), que pode não ser adequado para rios em baixa declividade, controlados hidraulicamente por cursos d'água de jusante ou submetido a efeito de remanso, que são condições observadas na porção mais baixa da BHRC. Nesta condição, o ajuste da rugosidade do canal pode ser útil para adequar a velocidade de propagação no canal e as características de propagação do hidrograma.

O resultado da calibração e verificação foi realizado utilizando os coeficientes NSE, KGE, R, RMSE, EMA e EM, além dos gráficos de dispersão e dos hidrogramas simulado e observado da bacia. O modelo hidrológico apresentou melhores resultados para a BHPS.

As características da BHPS justificam o melhor desempenho do modelo, uma vez que as características de uso e cobertura, tempo de concentração e comportamento hidráulico dos canais estão mais adequados com as premissas de funcionamento do modelo. A diferença de desempenho da BHRC se deve não só a limitação do tamanho amostral e do uso de um período de calibração sensivelmente mais úmido do que da validação, mas também as simplificações do modelo para representar a ocorrência de remanso e o controle hidráulico dos canais que ocorre na parte baixa da bacia.

Para realizar o processamento da previsão de precipitação foram testadas diferentes janelas móveis de dias de treinamento sendo que para a BHPS a janela de treinamento foi definida em 90 dias e para BHRC em 150 dias.

Os coeficientes determinísticos (R, EMA e EM) mostram para todas as bacias estudadas que o processamento das previsões de chuva associado com o ajuste da vazão de saída do modelo melhora a qualidade da previsão. Outro resultado observado em todas as bacias é que apenas o ajuste da vazão de saída (ou seja, utilizando as previsões de chuva brutas do ECMWF) reduz a qualidade da previsão. O BS indica resultados semelhantes nas duas bacias, comportamento semelhante para as previsões (brutas e processadas) sem ajuste da vazão de saída e melhor comportamento das previsões

processadas, principalmente do processamento com os modelos GEV e CSG, para o caso em que a vazão de saída é processada. O resultado segue o mesmo padrão para as duas bacias quando é feita a comparação com o CRPS.

Os resultados da curva ROC para as duas bacias indicam que o ajuste da vazão de saída isoladamente piora a capacidade de detecção de eventos. Por outro lado, o processamento da previsão de chuva melhora a capacidade de detecção e o melhor caso ocorre quando a previsão de chuva é processada (independente do modelo) e a vazão de saída da previsão é ajustada.

O diagrama de confiabilidade mostra resultados diferentes para cada uma das bacias. Para a BHPS o processamento das previsões mostra melhora no desempenho quando comparada com as previsões brutas do ECMWF. Para o caso da BHRC as curvas de calibração do diagrama apresentam comportamento errático e não indicam que o processamento da previsão promova melhoria neste quesito.

Os gráficos de *Rank* e PIT *Histogram* apresentam comportamento semelhante nas duas bacias. As previsões de vazão geradas com previsões brutas do ECMWF apresentam concentração dos membros do conjunto e isto é parcialmente melhorado quando é aplicado o processamento da precipitação. Embora os resultados para as previsões processadas indiquem melhora relativa da distribuição dos histogramas em relação à previsão bruta, ainda assim, o padrão de espalhamento apresentado nos histogramas das previsões processadas indica concentração das observações nos quantis superiores de modo que as previsões processadas apresentam viés negativo.

A análise dos hidrogramas do evento de máxima registrada no período sintetiza grande parte do que foi discutido. De modo geral, o ajuste da vazão de saída melhora a qualidade das previsões tanto o modelo hidrológico alimentado com as previsões brutas do ECMWF, quanto quando é alimentado pelos quantis de probabilidade das previsões processadas. O processamento com a BMA promove alguma melhora na previsão, porém, os quantis de probabilidade estão muito próximos, de modo que não é possível distinguir os quantis nos hidrogramas de previsão. Ou seja, os quantis de probabilidade estão muito concentrados em torno do mesmo valor e explicam o fato de que o processamento com a BMA melhora as estatísticas descritivas, mas é penalizado nas estatísticas que consideram o espalhamento dos membros. Por sua vez, o processamento com a GEV e com CSG mostra melhora no espalhamento dos quantis, que na maior parte dos casos (maioria dos postos fluviométricos e horizontes de previsão), formam um hidrograma de previsão que envolve o hidrograma observado, entre os modelos GEV e CSG, o segundo é o que apresenta o melhor desempenho.

Diante do apresentado, o processamento das previsões de precipitação melhora a qualidade da previsão hidrológica, esta melhora é mais pronunciada quando a previsão de vazão é ajustada pela tendência. Também é importante destacar que o uso de métricas que avaliam as previsões (de precipitação e de vazão) por conjunto sem reduzir a uma previsão determinística possibilitou avaliar de forma mais completa as previsões realizadas. Para a BHPS as métricas determinísticas isoladamente (R, EMA e EM) para previsão de precipitação não indicavam que o processamento da precipitação poderia promover ganho na previsão hidrológica, contudo foi verificado que há benefício para a previsão de precipitação e que esse benefício se propaga para as previsões hidrológicas.

Os resultados apresentados neste trabalho indicam que o benefício do processamento foi mais evidente nos casos em que a vazão prevista foi ajustada com base na última observação disponível, o que pode ser entendido como uma estratégia para contornar as incertezas envolvidas na modelagem hidrológica.

A respeito das previsões de precipitação, o potencial de outros modelos de previsão meteorológica pode ser avaliado. Além disso, é importante destacar que neste trabalho a chuva observada foi representada pelo produto de precipitação MSWEP. Esta escolha foi feita para manter uma base de informações comum entre bacias, dirimir os problemas usuais das bases observacionais (falhas, erros de leitura, leituras de acumulados) e garantir que os resultados das bacias fossem comparáveis.

Contudo, para fins operacionais, o processamento da previsão de precipitação deve ser realizado utilizando observações pluviométricas que, diferentemente do produto de precipitação utilizado, podem ser disponibilizadas em tempo real para que seja realizado o processamento da previsão.

### Sugestões para trabalhos futuros

Em trabalhos futuros outras estratégias podem ser testadas para contornar as limitações dos modelos hidrológicos, por exemplo, realizando assimilação de dados de vazão ou uma calibração dinâmica com dados atuais antes do início da previsão para reduzir a discrepância entre simulado e observado no início da previsão.

Outra possibilidade é contabilizar a incerteza da modelagem hidrológica, utilizando um "conjunto de modelos hidrológicos" ou utilizando o intervalo de parâmetros dado pelo algoritmo SUFI-2 para representar as incertezas da modelagem hidrológica, processar o resultado da vazão do modelo hidrológico utilizando técnicas semelhantes ao processamento realizado para processar a previsão de chuva.

Por conta das limitações impostas pela base de dados fluviométricos das bacias, neste trabalho foi utilizado o passo temporal de 24 h. Contudo, é interessante avaliar se a metodologia apresentada pode ser utilizada em escala de tempo subdiária. Este tipo de estudo é relevante principalmente em bacias hidrográficas de resposta rápida, com tempo de concentração de menos de 24 h e onde o ganho de algumas horas no horizonte de previsão representa um benefício significativo para tomada de decisão e proteção das populações vulneráveis.

## REFERÊNCIAS

ABBASPOUR, K. C.; ROUHOLAHNEJAD, E.; VAGHEFI, S.; SRINIVASAN, R.; YANG, H.; KLØVE, B. A continental-scale hydrology and water quality model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. Journal of Hydrology, [S. 1.], v. 524, p. 733–752, 2015. DOI: 10.1016/j.jhydrol.2015.03.027.

ABBASPOUR, Karim C.; YANG, Jing; MAXIMOV, Ivan; SIBER, Rosi; BOGNER, Konrad; MIELEITNER, Johanna; ZOBRIST, Juerg; SRINIVASAN, Raghavan. Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. Journal of Hydrology, [S. 1.], v. 333, n. 2–4, p. 413–430, 2007. DOI: 10.1016/j.jhydrol.2006.09.014.

ABBOTT, M. B.; BATHURST, J. C.; CUNGE, J. A.; O'CONNELL, P. E.; RASMUSSEN, J. An introduction to the European Hydrological System - Systeme Hydrologique Europeen, "SHE", 1: History and philosophy of a physically-based, distributed modelling system. Journal of Hydrology, [S. 1.], v. 87, n. 1–2, p. 45–59, 1986. DOI: 10.1016/0022-1694(86)90114-9.

ABOU RAFEE, S.; UVO, C.; MARTINS, J.; DOMINGUES, L. M.; FUJITA, T.; FREITAS, E. D. Large-scale hydrological modelling of the Upper Paraná River Basin. Water, [S. l.], v. 11, n. 5, 2019. Disponível em: https://www.mdpi.com/2073-4441/11/5/882/htm.

ADDOR, N.; JAUN, S.; FUNDEL, F.; ZAPPA, M. An operational hydrological ensemble prediction system for the city of Zurich (Switzerland): Skill, case studies and scenarios. Hydrology and Earth System Sciences, [S. 1.], v. 15, n. 7, p. 2327–2347, 2011. DOI: 10.5194/hess-15-2327-2011.

ALFIERI, Lorenzo; PAPPENBERGER, Florian; WETTERHALL, Fredrik; HAIDEN, Thomas; RICHARDSON, David; SALAMON, Peter. Evaluation of ensemble streamflow predictions in Europe. Journal of Hydrology, [S. l.], v. 517, p. 913–922, 2014. DOI: 10.1016/j.jhydrol.2014.06.035.

ALTHOFF, Daniel; RODRIGUES, Lineu Neiva. Goodness-of-fit criteria for hydrological models: Model calibration and performance assessment. Journal of Hydrology, [S. 1.], v. 600, 2021. DOI: 10.1016/j.jhydrol.2021.126674.

AMINYAVARI, Saleh; SAGHAFIAN, Bahram. Probabilistic streamflow forecast based on spatial post-processing of TIGGE precipitation forecasts. Stochastic Environmental Research and Risk Assessment, [S. l.], v. 33, n. 11–12, p. 1939–1950, 2019. DOI: 10.1007/s00477-019-01737-4.

ANA - AGÊNCIA NACIONAL DE ÁGUAS. Bacias Hidrográficas Ottocodificadas. 2012. Disponível em: https://metadados.snirh.gov.br/. Acesso em: 21 set. 2021.

ANA - AGÊNCIA NACIONAL DE ÁGUAS. SAR - Sistema de Acompanhamento de Reservatórios. 2020. Disponível em: https://www.ana.gov.br/sar/. Acesso em: 8 maio. 2020.

ANA - AGÊNCIA NACIONAL DE ÁGUAS. Hidroweb. 2021. Disponível em: https://www.snirh.gov.br/hidroweb/apresentacao. Acesso em: 21 set. 2021.

BÁRDOSSY, A.; DAS, T. Influence of rainfall observation network on model calibration and application. Hydrology and Earth System Sciences, [S. l.], v. 12, n. 1, p. 77–89, 2008. DOI: 10.5194/hess-12-77-2008.

BARTHOLMES, J. C.; THIELEN, J.; RAMOS, M. H.; GENTILINI, S. The European flood alert system EFAS - Part 2: Statistical skill assessment of probabilistic and deterministic operational forecasts. Hydrology and Earth System Sciences, [S. l.], v. 13, n. 2, p. 141–153, 2009. DOI: 10.5194/hess-13-141-2009.

BECK, Hylke E.; WOOD, Eric F.; PAN, Ming; FISHER, Colby K.; MIRALLES, Diego G.; VAN DIJK, Albert I. J. M.; MCVICAR, Tim R.; ADLER, Robert F. MSWep v2 Global 3-hourly 0.1° precipitation: Methodology and quantitative assessment. Bulletin of the American Meteorological Society, [S. 1.], v. 100, n. 3, p. 473–500, 2019. DOI: 10.1175/BAMS-D-17-0138.1.

BEVEN, K. J.; KIRKBY, M. J. A physically based, variable contributing area model of basin hydrology. Hydrological Sciences Bulletin, [S. l.], v. 24, n. 1, p. 43–69, 1979. DOI: 10.1080/02626667909491834.

BJERKNES, Vilhelm. Das Problem der Wettervorhersage, betrachtet von Standpunkt der Mechanik und Physik. Meteorol. Z., [S. l.], v. 21, p. 1–7, 1904.

BOUCHER, M. A.; TREMBLAY, D.; DELORME, L.; PERREAULT, L.; ANCTIL, F. Hydro-economic assessment of hydrological forecasting systems. Journal of Hydrology, [S. 1.], v. 416–417, p. 133–144, 2012. DOI: 10.1016/j.jhydrol.2011.11.042.

BUIZZA, Roberto; DU, Jun; TOTH, Zoltan; HOU, Dingchen. Major Operational Ensemble Prediction Systems (EPS) and the Future of EPS. In: Handbook of Hydrometeorological Ensemble Forecasting. [s.l: s.n.]. p. 151–193. DOI: 10.1007/978-3-642-39925-1\_14.

BURNASH, R. J. C.; FERRAL, R. L.; MCGUIRE, R. A. A generalized streamflow simulation system - Conceptual modeling for digital computers. [S. l.], 1973.

CALVETTI, Leonardo. Previsão hidrometeorológica probabilística na Bacia do Alto Iguaçu-PR com os modelos WRF e TopModel. 2011. University of São Paulo, [S. l.], 2011.

CAPOZZOLI, R. C.; FUJITA, T.; FREITAS, E. D. Avaliação dos campos de precipitação MSWEP, CHIRPS E MERGE para a bacia do Alto Rio Paraná. Simpósio Brasileiro de Recursos Hídricos, [S. l.], 2021. Disponível em: https://files.abrhidro.org.br/Eventos/Trabalhos/142/XXIV-SBRH0063-1-20210615-131213.pdf.

CASAGRANDE, Leandro; TOMASELLA, Javier; DOS SANTOS ALVALÁ, Regina Célia; BOTTINO, Marcus Jorge; DE OLIVEIRA CARAM, Rochane. Early flood warning in the Itajaí-Açu River basin using numerical weather forecasting and hydrological modeling. Natural Hazards, [S. 1.], v. 88, n. 2, p. 741–757, 2017. DOI: 10.1007/s11069-017-2889-0.

CEMADEN. Rede Observacional. 2024.

CLOKE, H. L.; PAPPENBERGER, F. Ensemble flood forecasting: A review. Journal of Hydrology, [S. l.], v. 375, n. 3–4, p. 613–626, 2009. DOI: 10.1016/j.jhydrol.2009.06.005.

CLOKE, Hannah L.; SCHAAKE, John C. Handbook of Hydrometeorological Ensemble Forecasting. 1. ed. Berlin: Springer, 2016. DOI: 10.1007/978-3-642-40457-3.

COLLISCHONN, Bruno; COLLISCHONN, Walter; AGRA, Sidnei; BORTOLI, Carlos. Reconstituição das vazões naturais do Rio Caí - RS a jusante da transposição no Sistema Salto Através de Modalgem Hidrológica. In: (ABRHidro, Org.)ANAIS DO XVII SBRHIDRO 2007, São Paulo. Anais [...]. São Paulo: ABRHidro, 2007. p. 1–16.

COLLISCHONN, Walter. Simulação Hidrológica de grandes Bacias. 2001. Universidade Federal do Rio Grande do Sul, [S. 1.], 2001. DOI: 10.21168/rbrh.v6n1.p95-118.

COMPANHIA ENERGÉTICA DO ESTADO DE SÃO PAULO (CESP). Uhe Jaguari. [s.l: s.n.]. Disponível em: http://agevap.org.br/gtaoh/apresentacao-cesp-10.11.14.pdf.

Companhia de Pesquisa de Recursos Minerais (CPRM). Sistema de Alertas para Eventos Críticos. 2024.

CRAWFORD, N. H.; LINSLEY, R. K. Digital simulation in hydrology: Stanford Watershed Model IV. Contemporary Hydrology, [S. l.], p. 157–158, 1966.

CROCHEMORE, Louise; RAMOS, Maria Helena; PAPPENBERGER, Florian. Bias correcting precipitation forecasts to improve the skill of seasonal streamflow forecasts. Hydrology and Earth System Sciences, [S. 1.], v. 20, n. 9, p. 3601–3618, 2016. DOI: 10.5194/hess-20-3601-2016.

CUO, Lan; PAGANO, Thomas C.; WANG, Q. J. A review of quantitative precipitation forecasts and their use in short- to medium-range streamflow forecasting. Journal of Hydrometeorology, [S. l.], v. 12, n. 5, p. 713–728, 2011. DOI: 10.1175/2011JHM1347.1.

DAY, Gerald N. Extended Streamflow Forecasting Using NWSRFS. Journal of Water Resources Planning and Management, [S. l.], v. 111, n. 2, p. 157–170, 1985. DOI: 10.1061/(asce)0733-9496(1985)111:2(157).

DEMARGNE, Julie et al. The science of NOAA's operational hydrologic ensemble forecast service. Bulletin of the American Meteorological Society, [S. l.], v. 95, n. 1, p. 79–98, 2014. DOI: 10.1175/BAMS-D-12-00081.1.

ECKEL, F. Anthony; WALTERS, Michael K. Calibrated probabilistic quantitative precipitation forecasts based on the MRF ensemble. Weather and Forecasting, [S. l.], v. 13, n. 4, p. 1132–1147, 1998. DOI: 10.1175/1520-0434(1998)013<1132:CPQPFB>2.0.CO;2.

EM-DAT. International Disaster Database. 2019. Disponível em: https://www.emdat.be/. Acesso em: 1 fev. 2019.

FAN, F. M.; COLLISCHONN, W.; QUIROZ, K. J.; SORRIBAS, M. V.; BUARQUE,

D. C.; SIQUEIRA, V. A. Flood forecasting on the Tocantins River using ensemble rainfall forecasts and real-time satellite rainfall estimates. Journal of Flood Risk Management, [S. 1.], v. 9, n. 3, p. 278–288, 2016. DOI: 10.1111/jfr3.12177.

FAN, Fernando Mainardi. Previsão Por Conjunto De Vazões Afluentes a Reservatórios Em Grandes Bacias Hidrográficas Brasileiras. 2015. Universidade Federal do Rio Grande do Sul, [S. 1.], 2015.

FAN, Fernando Mainardi; COLLISCHONN, Walter; MELLER, Adalberto; BOTELHO, Luiz César Mendes. Ensemble streamflow forecasting experiments in a tropical basin: The São Francisco river case study. Journal of Hydrology, [S. l.], v. 519, n. PD, p. 2906–2919, 2014. DOI: 10.1016/j.jhydrol.2014.04.038.

FAN, Fernando Mainardi; SCHWANENBERG, Dirk; COLLISCHONN, Walter; WEERTS, Albrecht. Verification of inflow into hydropower reservoirs using ensemble forecasts of the TIGGE database for large scale basins in Brazil. Journal of Hydrology: Regional Studies, [S. 1.], v. 4, n. PB, p. 196–227, 2015. DOI: 10.1016/j.ejrh.2015.05.012.

FUKA, Daniel R.; WALTER, M. Todd; MACALISTER, Charlotte; DEGAETANO, Arthur T.; STEENHUIS, Tammo S.; EASTON, Zachary M. Using the Climate Forecast System Reanalysis as weather input data for watershed models. Hydrological Processes, [S. 1.], v. 28, n. 22, p. 5613–5623, 2014. DOI: 10.1002/hyp.10073.

GLAHN, Harry R.; LOWRY, Dale A. The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. Journal of Applied Meteorology, [S. l.], v. 11, n. 8, p. 1203–1211, 1972. DOI: 10.1175/1520-0450(1972)011<1203:tuomos>2.0.co;2.

GNEITING, Tilmann; RAFTERY, Adrian E.; WESTVELD, Anton H.; GOLDMAN, Tom. Calibrated probabilistic forecasting using ensemble model output statistics and minimum CRPS estimation. Monthly Weather Review, [S. l.], v. 133, n. 5, p. 1098–1118, 2005. DOI: 10.1175/MWR2904.1.

GUPTA, Hoshin V.; KLING, Harald; YILMAZ, Koray K.; MARTINEZ, Guillermo F. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. Journal of Hydrology, [S. l.], v. 377, n. 1–2, p. 80–91, 2009. DOI: 10.1016/j.jhydrol.2009.08.003.

HAMILL, Thomas M.; HAGEDORN, Renate; WHITAKER, Jeffrey S. Probabilistic forecast calibration using ECMWF and GFS ensemble reforecasts. Part I: Two-meter temperatures. Monthly Weather Review, [S. 1.], v. 136, n. 7, p. 2608–2619, 2008. a. DOI: 10.1175/2007MWR2410.1.

HAMILL, Thomas M.; HAGEDORN, Renate; WHITAKER, Jeffrey S. Probabilistic forecast calibration using ECMWF and GFS ensemble reforecasts. Part II: Precipitation. Monthly Weather Review, [S. l.], v. 136, n. 7, p. 2620–2632, 2008. b. DOI: 10.1175/2007MWR2410.1.

HEGDAHL, Trine Jahr; ENGELAND, Kolbjørn; STEINSLAND, Ingelin; SINGLETON, Andrew. Pre- and postprocessing flood forecasts using Bayesian model averaging. Hydrology Research, [S. 1.], v. 54, n. 2, p. 116–135, 2023. DOI:

10.2166/nh.2023.024.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Organização do Território. 2020. Disponível em: https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/. Acesso em: 21 set. 2020.

JAIN, Sharad K.; SINGH, Vijay P. Hydrological Cycles, Models, and Applications to Forecasting. In: Handbook of Hydrometeorological Ensemble Forecasting. [s.l: s.n.]. p. 311–339. DOI: 10.1007/978-3-642-39925-1\_20.

JAVANSHIRI, Zohreh; FATHI, Maede; MOHAMMADI, Seyedeh Atefeh. Comparison of the BMA and EMOS statistical methods for probabilistic quantitative precipitation forecasting. Meteorological Applications, [S. 1.], v. 28, n. 1, 2021. DOI: 10.1002/met.1974.

JORGETTI, Tatiana; DA SILVA DIAS, Pedro Leite; DE FREITAS, Edmilson Dias. The relationship between South Atlantic SST and SACZ intensity and positioning. Climate Dynamics, [S. l.], v. 42, n. 11–12, p. 3077–3086, 2014. DOI: 10.1007/s00382-013-1998-z.

KALNAY, E. Atmospheric Modeling, Data Assimilation, and Predictability. [s.l.] : Cambridge University Press, 2003.

KOBIYAMA, Masato; CHECCHIA, Tatiane; SILVA, Roberto Valmir Da; SCHRÖDER, Paulo Henrique; GRANDO, Ângela; REGINATTO, Gisele Marilha Pereira. Papel da comunidade e da universidade no gerenciamento de desastres naturais. In: SIMPÓSIO BRASILEIRO DE DESASTRES NATURAIS 2004, Florianópolis. Anais [...]. Florianópolis: UFSC, 2004. p. 834–846. Disponível em: http://www.ceped.ufsc.br/wpcontent/uploads/2014/07/papel\_da\_comunidade\_e\_da\_uni..pdf.

LEGATES, David R.; MCCABE, Gregory J. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. Water Resources Research, [S. l.], v. 35, n. 1, p. 233–241, 1999. DOI: 10.1029/1998WR900018.

LI, Wentao; DUAN, Qingyun; MIAO, Chiyuan; YE, Aizhong; GONG, Wei; DI, Zhenhua. A review on statistical postprocessing methods for hydrometeorological ensemble forecasting. Wiley Interdisciplinary Reviews: Water, [S. l.], v. 4, n. 6, 2017. DOI: 10.1002/wat2.1246.

LIGHT. Usina Hidrelétrica Santa Branca. [s.l: s.n.]. Disponível em: http://agevap.org.br/gtaoh/apresentacao-light-10.05.16.pdf.

LINSLEY, R. K.; KOHLER, M. A.; PAULHUS, J. L. H. Hydrology for engineers. Third edition. [s.l: s.n.].

LUCATERO, Diana; MADSEN, Henrik; REFSGAARD, Jens C.; KIDMOSE, Jacob; JENSEN, Karsten H. Seasonal streamflow forecasts in the Ahlergaarde catchment, Denmark: The effect of preprocessing and post-processing on skill and statistical consistency. Hydrology and Earth System Sciences, [S. 1.], v. 22, n. 7, p. 3601–3617, 2018. DOI: 10.5194/hess-22-3601-2018.

LYNCH, Peter. The origins of computer weather prediction and climate modeling. Journal of computational physics, [S. 1.], v. 227, n. 7, 2008.

MCKAY, Michael D. Latin hypercube sampling as a tool in uncertainty analysis of computer models. Proceedings - Winter Simulation Conference, [S. l.], p. 557–564, 1992. DOI: 10.1145/167293.167637.

MEDINA, Hanoi; TIAN, DI. Comparison of probabilistic post-processing approaches for improving numerical weather prediction-based daily and weekly reference evapotranspiration forecasts. Hydrology and Earth System Sciences, [S. 1.], v. 24, n. 2, p. 1011–1030, 2020. DOI: 10.5194/hess-24-1011-2020.

MELLER, Adalberto. Previsão de cheias por conjunto em curto prazo. 1996. Universidade Federal do Rio Grande do Sul, [S. l.], 1996. DOI: 10.1590/s0102-33061996000200017.

NAGHETTINI, Mauro; PINTO, Eber José Andrade. Hidrologia Estatística. 1. ed. Belo Horizonte: Companhia de Pesquisa de Recursos Minerais, 2007.

NASA - SHUTTLE RADAR TOPOGRAPHY MISSION (SRTM). Shuttle Radar Topography Mission Global. 2013. Disponível em: https://srtm.csi.cgiar.org/srtmdata/. Acesso em: 18 set. 2021.

NATIONAL RESEARCH COUNCIL. Report of a Workshop on Predictability & Limits-To-Prediction in Hydrologic SystemsReport of a Workshop on Predictability & Limits-To-Prediction in Hydrologic Systems. [s.l: s.n.]. DOI: 10.17226/10337.

NGUYEN, Tam V.; DIETRICH, Jörg; DANG, Thanh Duc; TRAN, Dang An; VAN DOAN, Binh; SARRAZIN, Fanny J.; ABBASPOUR, Karim; SRINIVASAN, Raghavan. An interactive graphical interface tool for parameter calibration, sensitivity analysis, uncertainty analysis, and visualization for the Soil and Water Assessment Tool. Environmental Modelling and Software, [S. 1.], v. 156, 2022. DOI: 10.1016/j.envsoft.2022.105497.

NIETSCH, SL; ARNOLD, JG; KINIRY, JR; WILLIAMS, JR. SWAT: Soil and Water Assessment Tool theoretical documentation. Texas: Texas Water Resources Institute, 2009.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO (ONS). Manual de Procedimentos da Operação: Cadastro de Informações Operacionais Hidráulicas da Bacia do rio Paraíba do Sul. [s.l: s.n.].

PAIVA, R. C. D.; COLLISCHONN, W.; BONNET, M. P.; DE GONÇALVES, L. G. G. On the sources of hydrological prediction uncertainty in the Amazon. Hydrology and Earth System Sciences, [S. l.], v. 16, n. 9, p. 3127–3137, 2012. DOI: 10.5194/hess-16-3127-2012.

PEREIRA, Donizete; MARTINEZ, Mauro A.; PRUSKI, Fernando F.; DA SILVA, Demetrius D. Hydrological simulation in a basin of typical tropical climate and soil using the SWAT model part I: Calibration and validation tests. Journal of Hydrology: Regional Studies, [S. l.], v. 7, p. 14–37, 2016. DOI: 10.1016/j.ejrh.2016.05.002. Disponível em: http://dx.doi.org/10.1016/j.ejrh.2016.05.002.

PROJETO MAPBIOMAS. Coleção 6 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. 2020. Disponível em: https://mapbiomas.org/. Acesso em: 18 set. 2020.

PU, Zhaoxia; KALNAY, Eugenia. Numerical Weather Prediction Basics: Models,

Numerical Methods, and Data Assimilation. In: Handbook of Hydrometeorological Ensemble Forecasting. [s.l: s.n.]. p. 67–97. DOI: 10.1007/978-3-642-39925-1\_11.

QUEDI, Erik Schmitt; MAINARDI FAN, Fernando. Sub seasonal streamflow forecast assessment at large-scale basins. Journal of Hydrology, [S. l.], v. 584, n. July 2019, p. 124635, 2020. DOI: 10.1016/j.jhydrol.2020.124635.

RAFTERY, Adrian E.; GNEITING, Tilmann; BALABDAOUI, Fadoua; POLAKOWSKI, Michael. Using Bayesian model averaging to calibrate forecast ensembles. Monthly Weather Review, [S. l.], v. 133, n. 5, p. 1155–1174, 2005. DOI: 10.1175/MWR2906.1.

REBOITA, Michelle Simões; GAN, Manoel Alonso; PORFÍRIO, Rosmeri; ROCHA, D. A.; AMBRIZZI, Tércio. REGIMES DE PRECIPITAÇÃO NA AMÉRICA DO SUL : UMA REVISÃO BIBLIOGRÁFICA Departamento de Ciências Atmosféricas , Universidade de São Paulo (DCA / USP), São Paulo , SP, Brasil Instituto Nacional de Pesquisas Espaciais , Centro de Previsão de Tempo e Estudo. Revista Brasileira de Meteorologia, v.25, n.2, [S. 1.], p. 185–204, 2010.

RICCIARDI, Giuseppe; MONTANI, Andrea; PACCAGNELLA, Tiziana; PECORA, Silvano; TONELLI, Fabrizio. Forecasting skills of the ensemble hydro-meteorological system for the Po river floods. Geophysical Research Abstracts, [S. 1.], v. 15, p. 2013–7227, 2013.

RICHARDSON, Lewis Fry. Weather prediction by numerical process, second edition. [s.l.] : University Press, 1922. v. 9780521680 DOI: 10.1017/CBO9780511618291.

ROBERTSON, D. E.; SHRESTHA, D. L.; WANG, Q. J. Post-processing rainfall forecasts from numerical weather prediction models for short-term streamflow forecasting. Hydrology and Earth System Sciences, [S. l.], v. 17, n. 9, p. 3587–3603, 2013. DOI: 10.5194/hess-17-3587-2013.

SCHEUERER, M. Probabilistic quantitative precipitation forecasting using Ensemble Model Output Statistics. Quarterly Journal of the Royal Meteorological Society, [S. l.], v. 140, n. 680, p. 1086–1096, 2014. DOI: 10.1002/qj.2183.

SCHEUERER, Michael; HAMILL, Thomas M. Statistical postprocessing of ensemble precipitation forecasts by fitting censored, shifted gamma distributions. Monthly Weather Review, [S. l.], v. 143, n. 11, p. 4578–4596, 2015. DOI: 10.1175/MWR-D-15-0061.1.

SCHWANENBERG, Dirk; FAN, Fernando Mainardi; NAUMANN, Steffi; KUWAJIMA, Julio Issao; MONTERO, Rodolfo Alvarado; ASSIS DOS REIS, Alberto. Short-Term Reservoir Optimization for Flood Mitigation under Meteorological and Hydrological Forecast Uncertainty: Application to the Três Marias Reservoir in Brazil. Water Resources Management, [S. l.], v. 29, n. 5, p. 1635–1651, 2015. DOI: 10.1007/s11269-014-0899-1.

SECRETARIA DE MEIO AMBIENTE E INFRAESTRUTURA (SEMA). G030 - Bacia Hidrográfica do Rio Caí. 2020.

SENE, Kevin. Hydrometeorology: Forecasting and applications. Berlin: Springer, 2015. DOI: 10.1007/978-3-319-23546-2.

SHARMA, Sanjib; SIDDIQUE, Ridwan; REED, Seann; AHNERT, Peter; MENDOZA, Pablo; MEJIA, Alfonso. Relative effects of statistical preprocessing and postprocessing on a regional hydrological ensemble prediction system. Hydrology and Earth System Sciences, [S. 1.], v. 22, n. 3, p. 1831–1849, 2018. DOI: 10.5194/hess-22-1831-2018.

SIQUEIRA, Vinícius Alencar; COLLISCHONN, Walter; FAN, Fernando Mainardi; CHOU, Sin Chan. Previsão de cheias por conjunto a partir de previsões operacionais do EPS regional Eta na bacia do Taquari-Antas/RS. Revista Brasileira de Recursos Hidricos, [S. l.], v. 21, n. 3, p. 587–602, 2016. DOI: 10.1590/2318-0331.011616004.

SIQUEIRA, Vinícius Alencar; FAN, Fernando Mainardi; PAIVA, Rodrigo Cauduro Dias De; RAMOS, Maria Helena; COLLISCHONN, Walter. Potential skill of continental-scale, medium-range ensemble streamflow forecasts for flood prediction in South America. Journal of Hydrology, [S. l.], v. 590, n. May, 2020. DOI: 10.1016/j.jhydrol.2020.125430.

SLOUGHTER, J. Mc Lean; RAFTERY, Adrian E.; GNEITING, Tilmann; FRALEY, Chris. Probabilistic quantitative precipitation forecasting using bayesian model averaging. Monthly Weather Review, [S. l.], v. 135, n. 9, p. 3209–3220, 2007. DOI: 10.1175/MWR3441.1.

SZCZEŚNIAK, Mateusz; PINIEWSKI, Mikolłaj. Improvement of Hydrological Simulations by Applying Daily Precipitation Interpolation Schemes in Meso-Scale Catchments. Water (Switzerland), [S. 1.], v. 7, n. 2, p. 747–779, 2015. DOI: 10.3390/w7020747.

TANHAPOUR, Mitra; SOLTANI, Jaber; MALEKMOHAMMADI, Bahram; HLAVCOVA, Kamila; KOHNOVA, Silvia; PETRAKOVA, Zora; LOTFI, Saeed. Forecasting the Ensemble Hydrograph of the Reservoir Inflow based on Post-Processed TIGGE Precipitation Forecasts in a Coupled Atmospheric-Hydrological System. Water (Switzerland), [S. 1.], v. 15, n. 5, 2023. DOI: 10.3390/w15050887.

THIELEN, J.; BARTHOLMES, J.; RAMOS, M. H.; DE ROO, A. The European flood alert system - part 1: Concept and development. Hydrology and Earth System Sciences, [S. l.], v. 13, n. 2, p. 125–140, 2009. DOI: 10.5194/hess-13-125-2009.

THIEMIG, V.; BISSELINK, B.; PAPPENBERGER, F.; THIELEN, J. A pan-African medium-range ensemble flood forecast system. Hydrology and Earth System Sciences, [S. l.], v. 19, n. 8, p. 3365–3385, 2015. DOI: 10.5194/hess-19-3365-2015.

TODINI, E. History and perspectives of hydrological catchment modelling. Hydrology Research, [S. l.], v. 42, n. 2–3, p. 73–85, 2011. DOI: 10.2166/nh.2011.096.

TOMASELLA, J. et al. Probabilistic flood forecasting in the Doce Basin in Brazil: Effects of the basin scale and orientation and the spatial distribution of rainfall. Journal of Flood Risk Management, [S. 1.], v. 12, n. 1, p. 1–15, 2019. DOI: 10.1111/jfr3.12452.

TUCCI, Carlos Eduardo Morello; COLLISCHONN, Walter; CLARKE, Robin T.; PAZ, Adriano Rolin; ALLASIA, Daniel. Short- and long-term flow forecasting in the Rio Grande watershed (Brazil). Atmospheric Science Letters, [S. l.], v. 09, n. January, p. 53–56, 2009. DOI: 10.1002/asl.

TUNDISI, J. G. Recursos hídricos no Brasil: problemas, desafios e estratégias para o

futuro. Rio de Janeiro: Academia Brasileira de Ciências, 2014.

VALDEZ, Emixi Sthefany; ANCTIL, François; RAMOS, Maria Helena. Choosing between post-processing precipitation forecasts or chaining several uncertainty quantification tools in hydrological forecasting systems. Hydrology and Earth System Sciences, [S. 1.], v. 26, n. 1, p. 197–220, 2022. DOI: 10.5194/hess-26-197-2022.

VAN ANDEL, Schalk Jan; PRICE, Roland; LOBBRECHT, Arnold; VAN KRUININGEN, Frans; MUREAU, Robert; CORDERO, Wilmer Barreto. Framework for Anticipatory Water Management: Testing for Flood Control in the Rijnland Storage Basin. Journal of Water Resources Planning and Management, [S. 1.], v. 140, n. 4, p. 533–542, 2014. DOI: 10.1061/(asce)wr.1943-5452.0000254.

VERKADE, J. S.; WERNER, M. G. F. Estimating the benefits of single value and probability forecasting for flood warning. Hydrology and Earth System Sciences, [S. l.], v. 15, n. 12, p. 3751–3765, 2011. DOI: 10.5194/hess-15-3751-2011.

WETTERHALL, F. et al. HESS Opinions "forecaster priorities for improving probabilistic flood forecasts". Hydrology and Earth System Sciences, [S. l.], v. 17, n. 11, p. 4389–4399, 2013. DOI: 10.5194/hess-17-4389-2013.

WETTERHALL, Fredrik; SMITH, Paul. Hydrological Challenges in Meteorological Post-processing. In: DUAN, Qingyun; WOOD, Andy; PAPPENBERGER, F.; CLOKE, Hannah L.; SCHAAKE, John C. (org.). Handbook of Hydrometeorological Ensemble Forecasting. Berlin: Springer Nature, 2019. p. 239–253. DOI: 10.1007/978-3-642-39925-1\_15.

WILKS, Daniel. Statistical methods in the atmospheric sciences. [s.l: s.n.]. v. 53

WILKS, Daniel S. Maximum Likelihood Estimation for the Gamma Distribution Using Data Containing Zeros. Journal of Climate, [S. l.], v. 3, n. 12, p. 1495–1501, 1990. DOI: 10.1175/1520-0442(1990)003<1495:mleftg>2.0.co;2.

WU, Wenyan; EMERTON, Rebecca; DUAN, Qingyun; WOOD, Andrew W.; WETTERHALL, Fredrik; ROBERTSON, David E. Ensemble flood forecasting: Current status and future opportunities. WIREs Water, [S. l.], v. 7, n. 3, p. 1–32, 2020. DOI: 10.1002/wat2.1432.

YUAN, Huiling; TOTH, Zoltan; PEÑA, Malaquias. Handbook of Hydrometeorological Ensemble Forecasting. [s.l: s.n.]. p. 35–65. DOI: 10.1007/978.

## APÊNDICE A – Parâmetros utilizados no SWAT

Dorâmotro	Comodo	Latossolo (LVAd)	Argissolo (PVAd)	Cambissolo (CXbd)	Cambissolo	Planossolo	Neossolo	Nitossolo
1 al ameti 0	Camaua	(Pereira, 2013)	(Pereira,2013)	(Pereira,2013)	(Rafee et al., 2019)	(Rafee et al., 2019)	(Rafee et al., 2019)	(Rafee et al., 2019)
NLAYERS		4	6	6	5	5	1	6
HYDGRP	não se	А	С	В	В	С	А	В
SOL_ZMX	aplica	1400	1200	1000	1100	1400	200	1800
ANION_EXCL		0.38	0.32	0.47	0.47 0.5		0.5	0.5
SOL_Z1		200	200	200	300	200	200	150
SOL_BD1		1.14	1.19	1.08	1.4	1.4	1.35	1.4
SOL_AWC1		0.23	0.19	0.24	0.18	0.24	255	0.21
SOL_K1		75	65	45	2	1	2.5	1.5
SOL_CBN1	1	1.78	0.79	1.77	2	2	2	2
CLAY1		43	42	54	37	35	23	49
SILT1		10	10	11	18	54	58	41
SAND1		47	48	35	45	11	19	10
ROCK1		0	0	0	0	0	0	0
SOL_Z2		1400	1200	700	600	400	660.4	400
SOL_BD2		1.05	1.5	1.1	1.4	1.4	1.48	1.4
SOL_AWC2		0.27	0.28	0.27	195	135	0.13	0.18
SOL_K2		33	21	20	0.5	0.2	110	0.3
SOL_CBN2	2	1.4	0.19	0.92	0.5	0.5	0.68	0.5
CLAY2		62	61	57	34	68	7.5	56
SILT2		7	8	12	36	29	27.18	37
SAND2		31	31	31	30	3	65.32	7
ROCK2		0	0	0	0	0	7.91	0
SOL_Z3		1210	1000	1000	800	550	1524	650
SOL_BD3		1.7	1.4	1.4	1.4	1.4	1.58	1.4
SOL_AWC3		0.4	135	135	0.21	0.18	0.02	165
SOL_K3		12.5	1	1	0.7	0.2	550	0.3
SOL_CBN3	3	0.5	0.1	0.1	0.1	0.1	0.23	0.1
CLAY3		29.5	29	29	28.4	58	1	65
SILT3		13.8	11	11	37.7	41	6.53	29
SAND3		56.7	60	60	33.9	1	92.47	6
ROCK3		0	0	0	0	0	40	0
SOL_Z4		1500	1300	1300	1000	680	0	950
SOL_BD4		1.6	1.35	1.35	1.35	1.35	0	1.35
SOL_AWC4		0.4	0.21	0.21	0.21	0.14	0	0.21
SOL_K4		12.5	0.7	0.7	0.7	8	0	0.1
SOL_CBN4	4	0.4	0.1	0.1	0.1	0.05	0	0.7
CLAY4		35.6	26.8	26.8	26.8	27	0	26.8
SILT4		15.9	43.7	43.7	43.7	39.3	0	43.7
SAND4		48.5	29.5	29.5	29.5	33.7	0	29.5
ROCK4		0	0	0	0	0	0	0

Tabela 23- Parâmetros de solo utilizados na base de dados do SWAT

Fonte: Elaborado pelo autor com informações de Rafee et al. (2019) e Pereira et al. (2016)

SOL_Z5		0	1600	1600	1100	1400	0	1300
SOL_BD5		0	1.35	1.35	1.35	1.35	0	1.35
SOL_AWC5		0	0.14	0.14	0.14	0.14	0	0.14
SOL_K5		0	8	8	8	8	0	8
SOL_CBN5	5	0	0.05	0.05	0.05	0.05	0	0.05
CLAY5		0	27	27	27	27	0	27
SILT5		0	39.3	39.3	39.3	39.3	0	39.3
SAND5		0	33.7	33.7	33.7	33.7	0	33.7
ROCK5		0	0	0	0	0	0	0
SOL_Z6		0	2200	2200	0	0	0	1800
SOL_BD6		0	1.35	1.35	0	0	0	1.35
SOL_AWC6		0	0.15	0.15	0	0	0	135
SOL_K6		0	0.5	0.5	0	0	0	0.06
SOL_CBN6	6	0	0.06	0.06	0	0	0	0.3
CLAY6		0	35	35	0	0	0	75
SILT6		0	12	12	0	0	0	20
SAND6		0	53	53	0	0	0	5
ROCK6		0	0	0	0	0	0	0

Tabela A1 - Parâmetros de solo utilizados na base de dados do SWAT

Fonte: Elaborado pelo autor com informações de Rafee et al. (2019) e Pereira et al. (2016)

Tabela A2 - Parâmetros de superfície utilizados no SWAT

Calantaria	OV N		CN	2							IA	F					
Cobertura	UV_N	Α	В	С	D	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
FRSE	0.10	25	55	70	77	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0
PAST	0.15	49	69	79	84	3.0	3.0	2.5	2.0	1.0	1.0	1.0	1.0	1.0	1.5	2.5	3.0
WETN	0.05	49	69	79	84	2.0	2.0	2.0	2.0	1.0	1.0	1.0	1.0	2.0	2.0	2.0	2.0
RNGE	0.15	49	69	79	84	3.0	3.0	2.0	2.0	1.5	1.5	1.5	1.5	2.0	2.0	2.0	3.0
		0						SCS Runoff Curve Numbers					ers				
		0.1		Α		В			С			D					
URHD		0.1		31			59			72		79					
		UR	BCN2	N2 FIMP (fr			fraction) FCIMP (fraction)				)						
			98		0.	6			0.44								
		0	V N		SCS Runoff Curve Numbers												
URML		U	v_1		А				В			(	С			D	
			0.1		3	31		59			7	2			79		
	_	UR	BCN2	F	FIMP (f	ractior	I)	FCIN	AP (fr	action	)						
			98		0.	2			0.17								

Fonte: Elaborado pelo autor com informações de Nietsch et al. (2009)

# APÊNDICE B – Parâmetros de calibração utilizados no SWAT

Tabela B1 – Variação dos parâmetros de calibração em cada uma das rodadas de calibração para a bacia do Rio Paraíba do Sul

Rodada 1									
Parâmetro	Valor máximo								
CN2.mgt	relativa	-0.900	0.900						
SURLAG.hru	valor	0.100	10.000						
CANMX.hru	valor	0.000	100.000						
SOL_AWC.sol	relativa	-0.900	0.900						
OV_N.hru	valor	0.010	30.000						
LAT_TTIME.hru	valor	0.000	10.000						
ESCO.hru	valor	0.010	1.000						
	Rodad	la 2							
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo						
CN2.mgt	relativa	-0.621	0.790						
SURLAG.hru	valor	0.362	7.882						
CANMX.hru	valor	2.644	88.533						
SOL_AWC.sol	relativa	-0.733	0.792						
OV_N.hru	valor	3.903	26.732						
LAT_TTIME.hru	valor	0.046	9.107						
ESCO.hru	valor	0.131	0.920						
	Rodad	la 3							
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo						
CN2.mgt	relativa	-0.594	-0.066						
SURLAG.hru	valor	0.528	7.462						
CANMX.hru	valor	7.614	85.044						
OV_N.hru	valor	5.260	25.986						
LAT_TTIME.hru	valor	2.103	8.945						
	Rodad	la 4							
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo						
CN2.mgt	relativa	-0.582	-0.093						
SURLAG.hru	valor	0.638	7.238						
OV_N.hru	valor	6.592	25.262						
LAT_TTIME.hru	valor	4.363	8.856						
	Rodad	la 5							
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo						
CN2.mgt	relativa	-0.572	-0.199						
SURLAG.hru	valor	0.775	7.112						
OV_N.hru	valor	7.139	24.802						
LAT_TTIME.hru	valor	5.367	8.776						

	Roda	nda 1								
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo							
CN2.mgt	Relativa	-0.9	0.9							
SOL_K.sol	Relativa	-0.9	0.9							
RCHRG_DP.gw	Valor	0	1							
CH_N2.rte	Valor	0.01	0.3							
GWQMN.gw	Valor	0	5000							
CANMX.hru	Valor	0	100							
LAT_TTIME.hru	Valor	0	10							
Rodada 2										
Parâmetro Tipo de mudança Valor mínimo Valor máxim										
CN2.mgt	Relativa	-0.77	0.87							
SOL_K.sol	Relativa	-0.83	0.86							
RCHRG_DP.gw	Valor	0.042	0.9726							
CH_N2.rte	Valor	0.0172	0.2937							
GWQMN.gw	Valor	121.43	4885.2							
CANMX.hru	Valor	1.805	97.47							
LAT_TTIME.hru	Valor	0.2148	9.68							
	Roda	nda 3								
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo							
CN2.mgt	Relativa	-0.74	0.82							
SOL_K.sol	Relativa	-0.79	0.81							
RCHRG_DP.gw	Valor	0.066	0.9478							
CH_N2.rte	Valor	0.0245	0.2867							
GWQMN.gw	Valor	245.36	4762.4							
CANMX.hru	Valor	4.220	94.97							
LAT_TTIME.hru	Valor	0.4644	9.43							
	Roda	ada 4								
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo							
CN2.mgt	Relativa	-0.70	0.78							
SOL_K.sol	Relativa	-0.75	0.77							
RCHRG_DP.gw	Valor	0.089	0.9253							
CH_N2.rte	Valor	0.0314	0.2801							
GWQMN.gw	Valor	364.37	4641.3							
CANMX.hru	Valor	6.583	92.63							
LAT_TTIME.hru	Valor	0.6946	9.20							
	Roda	ada 5								
Parâmetro	Tipo de mudança	Valor mínimo	Valor máximo							
CN2.mgt	Relativa	-0.62	0.71							
SOL_K.sol	Relativa	-0.67	0.69							
RCHRG_DP.gw	Valor	0.131	0.8832							
CH_N2.rte	Valor	0.0445	0.2676							
GWQMN.gw	Valor	577.95	4425.8							
CANMX.hru	Valor	11.0777	88.33							
LAT_TTIME.hru	Valor	1.1213	8.78							

Tabela B2 – Variação dos parâmetros de calibração em cada uma das rodadas de calibração para a bacia do rio Caí

### APÊNDICE C – Resultados completos de calibração e validação do modelo hidrológico e de previsão de vazão para a BHPS

### Calibração e validação do modelo hidrológico

A seleção do melhor conjunto de parâmetros foi feita considerando o melhor resultado da média da função objetivo em todos os pontos em que há observação disponível. Neste caso, o melhor conjunto de parâmetros é selecionado de acordo com a média do coeficiente de Nash dos 5 postos de observação de vazão existentes na bacia. A figura c1a mostra o coeficiente de Nash de cada posto individualmente que compõem o coeficiente médio usado para seleção da melhor simulação.

Nas estações Santa Cecília, Ponte Alta I e Estrada do Cunha (Cunha) há pouca variação entre as rodadas, sendo que a estação de Santa Cecília apresenta o melhor resultado (Nash mais próximo de 1) entre todas as estações. Nas estações São Luís do Paraitinga e Santa Branca o valor do coeficiente de Nash reduz entre a segunda e a quarta rodada. O conjunto de parâmetros da segunda rodada apresenta, tanto individualmente quanto em termos da média de todos os pontos, o melhor coeficiente de Nash.

Um ponto de atenção é que a seleção pela média pode não ser representativa para todos os postos, uma vez que a média pode ser distorcida por valores muito altos ou muito baixos em um ponto específico. Esta questão pode ser analisada na Figura C1b, que apresenta o maior coeficiente de Nash obtido em cada uma das 5 rodadas de 500 simulações para cada posto individualmente. Neste gráfico observa-se que o comportamento do melhor coeficiente é semelhante ao gráfico que mostra o coeficiente de Nash do melhor conjunto de parâmetros considerando a média dos coeficientes para as vazões observadas. Deste modo, o conjunto de parâmetros da segunda rodada será selecionado para as futuras simulações na bacia do rio Paraíba do Sul.



Figura C1– Coeficiente de Nash da melhor simulação, de acordo com a média do coeficiente de Nash, em cada uma das cinco rodadas de 500 simulações realizadas.

Fonte: Elaborado pelo autor.

Analisando a **Erro! Fonte de referência não encontrada.**, que apresenta os idrogramas e o gráfico de dispersão das vazões simuladas e observadas, nota-se que o modelo representa a variabilidade sazonal da bacia e subestima principalmente o período seco e vazões altas.



Figura C2 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos fluviométricos da bacia do rio Paraíba do Sul no período de calibração.

Fonte: Elaborado pelo autor.

Os mesmos coeficientes e gráficos para o período de validação são mostrados na Tabela C1 e Figura C3. O posto Ponte Alta I apresenta o pior desempenho na validação, há dificuldade em representar a variabilidade de alta frequência que o posto apresenta neste período e o período seco também não é bem representado. O posto Cunha apresenta melhora na representação da vazão no período de validação, porém ainda há subestimativa das vazões no período seco e dos picos do hidrograma. No posto S.L. do Paraitinga os coeficientes de avaliação indicam melhora na representação do modelo, contudo, o modelo ainda subestima as vazões do período seco e as vazões altas. Os coeficientes indicam redução na qualidade da representação da vazão no posto Santa

Branca no período de validação que também apresenta dificuldades na representação das vazões no período seco e dos picos do hidrograma. Novamente o posto Santa Cecília apresenta o melhor desempenho e ainda que os coeficientes indiquem redução na qualidade da vazão simulada no período de validação, a representação das vazões é aceitável neste posto.

Tabela C1 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (EMA) e Erro Médio (EM) para o período de validação

Docto	NSF	KCF	D	DMSE	FMA	FM
1 0810	INDE	KGE	K	NUSE	LIVIA	
Santa Cecília	0,59	0,67	0,88	105,08	85,56	-68,7
Estrada do Cunha	0,19	0,58	0,74	7,00	5,51	-3,44
São Luís do Paraitinga	0,38	0,65	0,79	13,53	10,52	-5,3
Ponte Alta I	-0,06	0,43	0,59	5,00	3,41	-2,62
Santa Branca	0,40	0,63	0,82	32,77	26,09	-12,92

Fonte: Elaborado pelo autor.



Figura C3 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos fluviométricos da bacia do rio Paraíba do Sul no período de validação.

Fonte: Elaborado pelo autor.

#### Comparação entre as previsões de vazão bruta e probabilísticas

A Figura C4 apresenta o resultado das correlações para todo o período. O comportamento das vazões sem ajuste mostra que a correlação diminui à medida que o horizonte de previsão aumenta e em todos os casos se observa que todas as previsões se iniciam com valor de correlação próximo, uma vez que há maior influência das condições iniciais e à medida que o horizonte de previsão avança a correlação da previsão de vazão realizada com a previsão bruta do ECMWF diminui mais rapidamente do que as previsões geradas com os modelos probabilísticos propostos.

A exceção deste comportamento ocorre no posto Ponte Alta I, em que a correlação para todas as previsões em todos os horizontes de tempo se mantém constante, contudo, este posto possui a menor área de drenagem da bacia e o valor do coeficiente de correlação registrado (0,34) está entre os menores de todos os postos de monitoramento em todos os horizontes de previsão. Ainda, para as previsões sem ajuste da vazão, o coeficiente de correlação aumenta em função do aumento da área de drenagem, sendo este comportamento mais proeminente no horizonte de tempo de 24 h.

Para as previsões ajustadas se destaca que a correlação aumenta consideravelmente em todos os postos de monitoramento para as previsões processadas com os modelos probabilísticos e que há um padrão de aumento da correlação entre os horizontes de tempo de 24 h e 48 h. As previsões geradas com quantis de probabilidade também mostram aumento da correlação em função do aumento da área de drenagem. As correlações para as previsões brutas do ECMWF são baixas, ficando próximas de zero e, em alguns casos, negativas.

Figura C4 – Coeficiente de correlação (R) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste e os postos estão ordenados da menor para maior área de drenagem.



Fonte: Elaborado pelo autor.

O valor do erro médio absoluto em função do horizonte de previsão é mostrado na Figura C5. De modo geral, o erro absoluto para as previsões sem ajuste se comporta de maneira semelhante, tanto paras as previsões brutas do ECMWF quanto para as previsões geradas por quantis de probabilidade. O erro absoluto também aumenta ligeiramente em função do horizonte de previsão. Para as previsões ajustadas é notória a distinção de comportamento das previsões brutas do ECMWF e das previsões processadas, na primeira o erro absoluto apresenta maior magnitude e maior aumento do erro em função do horizonte de previsão quando comparada com a segunda. Figura C5 – Erro médio absoluto (EMA) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

O resultado do EM é apresentado na Figura C6. Dos resultados apresentados é possível notar que as previsões brutas do ECMWF com a vazão de saída ajustada apresentam viés negativo e, em geral, a magnitude do erro é alta, sendo que a magnitude do erro médio aumenta em função do horizonte de previsão, de modo que a previsão bruta do ECMWF sem ajuste da vazão de saída apresenta desempenho melhor do que com a vazão de saída ajustada. A respeito das previsões processadas, ainda que em alguns casos, nos primeiros horizontes (24 h a 48 h), o desempenho da previsão processada sem ajuste da vazão de saída tenha desempenho comparável às previsões processadas com a juste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vazão de saída, as previsões processadas com ajuste da vazão de saída com ajuste da vaz

Figura C6 – Erro médio relativo (EMR) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.
A Figura C7 apresenta o resultado do BS, considerando como limiar de cheia o percentil 75% da vazão. O resultado do BS mostra que as previsões geradas com os modelos probabilísticos GEV e CSG tem menor variação nos valores de BS em função do horizonte de previsão. As previsões processadas com o modelo probabilístico BMA e as previsões brutas do ECMWF apresentam aumento no BS em função do horizonte de tempo quando comparada com as previsões processadas com os modelos GEV e CSG. Este resultado é valido tanto para as previsões com a vazão sem ajuste da vazão de saída quanto com ajuste das vazões de saída, porém, para as previsões com ajuste da vazão de saída o resultado apresenta valores de BS mais próximos de zero, ou seja, o desempenho das previsões processadas com os modelos GEV e CSG e com as vazões de saída ajustadas apresentam o melhor desempenho de previsão.

Figura C7 – *Brier Score* (BS) considerando como limiar de cheia o percentil 75% da vazão, e vazão observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

A Figura C8 apresenta o CRPS para previsões processadas e para as previsões brutas do ECMWF, considerando a vazão de saída sem ajuste e com ajuste da vazão de saída. Os resultados do CRPS mostram que as previsões processadas sem ajuste da vazão possuem erros semelhantes ao encontrado para a previsão bruta do ECMWF. Já as previsões processadas (independe do modelo utilizado) e com a vazão de saída ajustada possuem os menores valores de CRPS, indicando que esta categoria de previsão apresenta o menor erro entre o que foi avaliado. As previsões com a chuva processada e com a vazão ajustada também apresentaram menor variação do CRPS em função do horizonte de previsão. Figura C8 – *Continuous Ranked Probability Score* (CRPS) entre a vazão prevista e a observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

A curva ROC para previsões de vazão é mostrada na Figura C9. As curvas das previsões ajustadas indicam um resultado melhor do que as previsões sem ajustes. O comportamento da curva para a previsão gerada com o modelo BMA é a que apresenta o padrão mais próximo do ideal, seguida das curvas para a previsão gerada com os modelos GEV e CSG. A capacidade de discriminação dos modelos diminui em função do horizonte de previsão, sendo que esta redução de discriminação dos modelos é mais destacada nas previsões brutas do ECMWF (sem ajuste e ajustadas) e mais discreta nas previsões geradas com os modelos probabilísticos com a vazão ajustada.

Este resultado indica que o ajuste com os modelos probabilísticos melhora a capacidade de discriminação das previsões de vazão quando comparada com a previsão bruta do ECMWF, sendo que o modelo BMA foi o que apresentou a melhor capacidade de discriminação.

Figura C9 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às previsões sem ajuste da vazão (ajustada).



Fonte: Elaborado pelo autor.

As figuras Figura C10 a Figura C14 mostram o diagrama de confiabilidade da previsão de vazão utilizando a precipitação bruta do ECMWF e com a precipitação processada, em ambos os casos com a vazão de saída ajustada. Foi considerado o percentil 75% da vazão como limiar para ocorrência de eventos. Os resultados sem ajuste da vazão de saída são, em todas as condições, piores do que com ajuste da vazão de saída e, por brevidade, as figuras foram omitidas.

De modo geral, a previsão de vazão utilizando a precipitação processada com o modelo BMA é a que apresenta o pior desempenho, em todas as estações. O resultado das previsões de vazão com a previsão de precipitação bruta do ECMWF apresenta baixa resolução em todas as estações e horizontes de previsão e os gráficos de refinamento da distribuição indicam boa confiança dos modelos de previsão.

Os resultados dos diagramas de confiabilidade dos modelos GEV e CSG indicam, em todos os casos, que o processamento melhora a correspondência entre a probabilidade condicional de previsão, quando comparados com as previsões brutas do ECMWF e do modelo probabilístico BMA. Já os resultados das curvas de calibração são variados de acordo com o posto fluviométrico e o horizonte de previsão.

A curva de calibração dos modelos GEV e CSG para a estação Ponte Alta I no horizonte de 24 h indica viés seco para previsões de probabilidade de previsão baixa à intermediária e viés úmido para probabilidades mais altas. Para os horizontes de previsão de 48 h a 120 h o padrão das curvas de calibração indica boa resolução.

Para estação Estrada do Cunha no horizonte de 24 h a curva de calibração dos modelos GEV e CSG indicam viés seco. Para os demais horizontes de previsão o viés seco se acentua.

O resultado dos modelos GEV e CSG para estação São Luís do Paraitinga apresenta comportamento errático no horizonte de 24 h, para 48 h os modelos GEV e CSG se comportam dentro do ideal para eventos com probabilidade de previsão baixa à intermediária e para os demais horizontes a curva de calibração segue o padrão de boa resolução.

A estação Santa Branca apresenta curva de calibração para o horizonte de 24 h com bom ajuste para probabilidades de previsão baixa a intermediária. Para o horizonte de 48 h o padrão é semelhante, com tendência de viés seco. O resultado é melhor, com curvas próximas do ideal, em todas as probabilidades de previsão para os horizontes de previsão de 72 h a 120 h.

A curva de calibração para o horizonte de 24 h da estação Santa Cecília apresenta bom ajuste para probabilidades de previsão baixa a intermediária. Para os demais horizontes (48 h a 120 h) as previsões de probabilidade de previsão baixa (alta) possui viés úmido (seco) padrão que indica boa resolução dos modelos GEV e CSG.

Figura C10 – Diagrama de Confiabilidade (*Reliability Diagram*) da estação Ponte Alta I utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado



Fonte: Elaborado pelo autor.



Figura C11 – Mesmo que na Figura C10, mas para a estação Estrada do Cunha

Fonte: Elaborado pelo autor.





Fonte: Elaborado pelo autor.



Figura C13 – Mesmo que na Figura C10, mas para a estação Santa Branca

Fonte: Elaborado pelo autor.

Figura C14 - Mesmo que na Figura C10, mas para a estação Santa Cecília



Fonte: Elaborado pelo autor.

Os *rank histograms* para a previsão de vazão gerada com o modelo hidrológico alimentado com as previsões brutas do ECMWF para horizontes de previsão de 24 h a 120 h, são apresentados na Figura C15. A primeira classe do histograma indica a frequência com que a vazão observada ficou próxima ou abaixo dos membros que indicam menor vazão, enquanto a última classe indica a frequência com que a vazão observada ficou próxima ou superou a vazão prevista pelos membros que indicam maior precipitação.

Para as previsões sem processamento, os *rank histograms* de todos os horizontes de tempo apresentam formato de "U". Este tipo de formato indica concentração excessiva dos membros do conjunto. A concentração excessiva indica que os membros são pouco espalhados e as observações se posicionam frequentemente nas classes extremas, neste caso há excesso de confiança na previsão, cujos membros indicam valores semelhantes entre si. O resultado é bem semelhante em todas as estações de monitoramento da bacia e em todos os horizontes de tempo de previsão.

Figura C15 – *Rank Histogram* para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.



Fonte: Elaborado pelo autor.

Para permitir a comparação entre os *rank histograms* das previsões brutas com os PIT *histograms* das previsões processadas, foi utilizado o mesmo número de classes (10). A Figura C16 apresenta o resultado para a previsão de vazão com o modelo hidrológico alimentado com a chuva processada utilizando os modelos BMA, GEV e CSG. Nota-se que os histogramas apresentam um padrão do tipo "U" para o resultado do modelo BMA. O resultado com os modelos GEV e CSG apresentam comportamento semelhante entre si. Neste padrão há uma concentração de observações na primeira

classe, indicando que há um grande número de casos em que as observações são menores que a menor previsão, combinado com um padrão de "rampa" com as observações se posicionando majoritariamente entre a probabilidade intermediária à alta. O resultado do PIT *histogram* está longe do padrão ideal, contudo, comparado com as previsões brutas do ECMWF, há melhora na qualidade da previsão de vazão (especificamente na dispersão dos membros do conjunto) utilizando a precipitação processada com o modelo GEV e CSG.

Figura C16 – PIT *histograms* para previsões de precipitação processadas da BRPS em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis



Fonte: Elaborado pelo autor.

## Hidrogramas de previsão da vazão máxima registrada

Este item é dedicado à avaliação dos hidrogramas previstos para a máxima registrada em cada um dos postos de monitoramento fluviométrico da bacia. A Tabela C2 apresenta a data e a vazão registrada na máxima em cada posto fluviométrico utilizado. Somente nos postos Ponte Alta I e Santa Branca o evento da máxima está em datas próximas, de modo que a máxima nestes postos foi ocasionada pela mesma precipitação.

montorumento.						
Posto de monitoramento	Data da máxima	Vazão registrada $(m^3 s^{-1})$				
Ponte Alta I	08/11/2018	75,8				
Cunha	22/03/2018	48,1				
São Luís do Paraitinga	19/03/2019	98,6				
Santa Branca	09/11/2018	277,1				
Santa Cecília	05/03/2018	785,6				

Tabela C2 – Data e valor da vazão máxima registrada no período de estudo em cada posto de monitoramento

Fonte: Elaborado pelo autor.

Os hidrogramas de previsão de vazão do posto Ponte Alta I são mostrados na Figura C17. Para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e sem ajuste da vazão de saída, nenhum membro da previsão indica vazão próxima do valor da máxima no dia do evento, em nenhum horizonte de previsão. Já para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e com ajuste da vazão de saída, o resultado é melhor. Na previsão com 24 h de antecedência, a vazão prevista subestima a vazão observada e todos os membros registram vazão menor que 50  $m^3 s^{-1}$ , para previsão com 48 h de antecedência um membro superestima a vazão observada enquanto dois membros registram vazão igual ou maior que 50  $m^3 s^{-1}$ , as previsões dos demais membros se concentram na faixa abaixo de 25  $m^3 s^{-1}$ , para a previsão com 72 h e 96 h de antecedência a previsão subestima a vazão observada em todos os membros.

As previsões de vazão alimentadas com as previsões processadas com o modelo BMA apresentam pouco espalhamento dos membros. A previsão sem ajuste não representa nenhuma capacidade de previsão. Já na previsão ajustada nota-se que há melhora nas subestimativas de vazão nos horizontes de 48 h a 120 h (quando comparadas com a previsão bruta do ECMWF).

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída, ainda que haja alguma melhora no espalhamento, os hidrogramas de previsão não conseguem representar a vazão observada no evento. Por outro lado, as previsões ajustadas apresentam melhora considerável no espalhamento e a vazão observada fica situada entre os quantis de probabilidade 65% e 75% nos horizontes de 48 h a 96 h e entre 75% e 85% no horizonte de 120 h. O resultado para previsões processadas com o modelo CSG apresenta o mesmo padrão.



Figura C17 – Hidrogramas de previsão da máxima de vazão do período de estudo para o posto Ponte Alta I. A linha tracejada horizontal indica o dia do evento e a linha tracejada em vermelho a vazão observada.

Fonte: Elaborado pelo autor.

A Figura C18 apresenta os hidrogramas de previsão para o posto Estrada do Cunha. Para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e sem ajuste da vazão de saída, todos os membros subestimam a vazão observada no posto. Nota-se que há aumento do espalhamento dos membros à medida que o horizonte de previsão se amplia. Para o caso das previsões brutas do ECMWF e com ajuste da vazão de saída, o resultado apresenta alguma melhora na previsão. Para a previsão com 24 h de antecedência os membros apresentam bom espalhamento no entorno da vazão observada, para os horizontes de previsão de 48 h a 96 h todos os membros subestimam a vazão e no horizonte de 120 h as previsões mostram bom espalhamento no entorno da vazão observada.

As previsões alimentadas com as previsões processadas com o modelo BMA seguem o mesmo padrão do posto anterior, com pouco espalhamento dos membros (sem ajuste e com ajuste da vazão de saída). A previsão sem ajuste não representa nenhuma capacidade de previsão. Já na previsão ajustada nota-se que há melhora nas subestimativas de vazão nos horizontes de 48 h a 120 h (quando comparadas com a previsão bruta do ECMWF).

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída mostra melhora no espalhamento em relação às previsões brutas do ECMWF. Entre os horizontes de 24 h a 72 h todos os quantis de previsão ficam abaixo da vazão observada. Para o horizonte de 96 h e 120 h a vazão observada fica entre os quantis de 85% e 95%. O ajuste da vazão de saída mostra ganho em relação à vazão sem ajuste. Para o horizonte de 24 h a vazão observada fica entre os quantis de 85% e 95%. O ajuste da vazão observada fica entre os quantis de 75% e 85%, no horizonte de 48 h a vazão observada fica entre os quantis de 55% e 65%, para as previsões com 72 h a 120 h de antecedência, a vazão observada fica entre os quantis 45% e 55%.

Para as previsões processadas com o modelo CSG o resultado é semelhante ao anterior. Para a previsão sem ajuste da vazão de saída nos horizontes de 24 h e 48 h todos os quantis de previsão ficam abaixo da vazão observada. Entre os horizontes de 72 h e 120 h a vazão observada fica entre os quantis de 85% e 95%. O ajuste da vazão de saída melhora o espalhamento em relação à vazão sem ajuste. Para o horizonte de 24 h a vazão observada fica entre os quantis de 75% e 85%, nos horizontes de 48 h e 72 h a vazão observada fica entre os quantis de 55% e 65%, para as previsões com 96 h e 120 h a vazão observada está entre os quantis 45% e 55%.



Figura C18 – Mesmo que na Figura C17, mas para a estação Estrada do Cunha.

Fonte: Elaborado pelo autor.

Os hidrogramas do posto São Luís do Paraitinga são mostrados na Figura C19. Para as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e sem ajuste da vazão de saída, nas previsões de horizonte de 24 h e 48 h todos os membros subestimam a vazão observada no posto. Para as previsões de 72 h a 120 h os membros se distribuem no entorno da vazão observada. O espalhamento melhora em função do aumento do horizonte de previsão. Para o caso das previsões brutas do ECMWF, e com ajuste da vazão de saída, o resultado se altera. Em todos os horizontes de previsão os membros ficam abaixo da vazão observada, contudo, a diferença é mais acentuada nos horizontes de 48 h, 96 h e 120 h.

As previsões alimentadas com as previsões processadas com o modelo BMA seguem o mesmo padrão do posto anterior, com pouco espalhamento dos membros (sem ajuste e com ajuste da vazão de saída). A previsão sem ajuste não representa nenhuma capacidade de previsão. Já a previsão com a vazão de saída ajustada apresenta melhor capacidade de representar o hidrograma observado, contudo, sempre subestimando as vazões.

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída mostra melhora no espalhamento em relação às previsões brutas do ECMWF. No horizonte de 24 h a vazão observada se localiza entre os quantis de previsão de 85% e 95%, no horizonte de 48 h e 72 h (96 h e 120 h) a vazão observada fica entre os quantis de previsão de 55% e 65% (35% e 45%).

O resultado para as previsões processadas com o modelo CSG apresenta ligeira melhora na capacidade de previsão em relação ao anterior. Para a previsão sem ajuste da vazão de saída nos horizontes de 24 h e 48 h a vazão observada fica entre os quantis 85% e 95%. Entre os horizontes de 72 h e 96 h a vazão observada fica entre os quantis de 75% e 85% e no horizonte de 120 h entre os quantis de 65% e 75%. O ajuste da vazão de saída melhora o espalhamento em relação à vazão sem ajuste. Para o horizonte de 24 h a vazão observada fica entre os quantis de 85% e 95%, no horizonte de 48 h a vazão observada fica entre os quantis de 55% e 65%, para as previsões com 72 h a vazão observada está entre os quantis 45% e 55%, para o horizonte de 96 h a vazão observada fica entre os quantis 45% e 55%, para o horizonte de 96 h a vazão observada fica entre os quantis 45% e 55%, para o horizonte de 96 h a vazão observada fica entre os quantis 45% e 55%.



Figura C19 – Mesmo que na Figura C17, mas para a estação São Luís do Paraitinga.

Fonte: Elaborado pelo autor.

Os hidrogramas do posto Santa Branca são mostrados na Figura C20. Diferente dos demais casos apresentados, neste posto as previsões com o modelo hidrológico alimentado com as previsões brutas do ECMWF e sem ajuste da vazão de saída apresentam grande concentração das previsões em todos os horizontes de previsão. O ajuste da vazão de saída melhora o espalhamento das previsões, principalmente entre os horizontes de 48 h e 120 h, ainda assim a tendência é de subestimar a vazão observada.

As previsões alimentadas com as previsões processadas com o modelo BMA seguem o mesmo padrão do posto anterior, com pouco espalhamento dos membros (sem ajuste e com ajuste da vazão de saída). A previsão sem ajuste não representa nenhuma capacidade de previsão. Já a previsão com a vazão de saída ajustada apresenta melhor capacidade de representar o hidrograma observado, contudo, sempre subestimando as vazões.

Para as previsões processadas com o modelo GEV o resultado da previsão sem ajuste da vazão de saída mostra pouca capacidade de previsão em todos os horizontes. O ajuste da vazão de saída melhora consideravelmente a capacidade de previsão, no horizonte de 24 h a vazão observada se localiza entre os quantis de 85% e 95%, no horizonte de 48 h a vazão observada fica entre os quantis de 75% e 85% e nos horizontes de 72 h a 120 h entre 65% e 75%. O resultado para as previsões processadas com o modelo CSG é bastante semelhante ao anterior.



Figura C20 – Mesmo que na Figura C17, mas para a estação Santa Branca.

Fonte: Elaborado pelo autor.

## APÊNDICE D – Resultados completos de calibração e validação do modelo hidrológico e de previsão de vazão para a BHRC

## Calibração e validação do modelo hidrológico

A seleção do melhor conjunto de parâmetros foi feita considerando o melhor resultado da média da função objetivo em todos os postos em que há observação disponível. Neste caso, o melhor conjunto de parâmetros é selecionado de acordo com a média do coeficiente de Nash dos 5 postos de vazão observada utilizados para modelagem da bacia. A Figura D1a mostra o coeficiente de Nash de cada posto para a melhor simulação em cada uma das cinco rodadas de 500 simulações realizadas.

Na estação Linha Gonzaga o coeficiente de Nash reduz na terceira rodada e em seguida volta para mesma faixa de valores das duas primeiras rodadas. Para estação Nova Palmira a variação é pequena entre as simulações, já no posto Costa R. Cadeia o coeficiente de Nash reduz da segunda rodada em diante. O inverso ocorre na estação Barca do Caí na qual o coeficiente de Nash aumenta a partir da segunda rodada. Para a estação Passo Montenegro a variação é pequena entre as simulações, com redução do coeficiente de Nash na segunda rodada.

Um ponto de atenção é que a seleção pela média pode não ser representativa para todos os postos e este ponto é evidenciado na Figura D1b. Nota-se que a simulação em que se obtém o maior coeficiente de Nash em cada posto é diferente da simulação selecionada pela média do coeficiente de Nash e em algumas rodadas esta diferença é acentuada. Na primeira rodada a seleção pela média indica valores de Nash próximos do melhor obtido nas 500 simulações em 4 postos (Linha Gonzaga, Nova Palmira, Costa do Rio Cadeia e Passo Montenegro), na segunda rodada 3 postos (Linha Gonzaga, Nova Palmira, Costa do Rio Cadeia, na terceira rodada apenas 2 postos (Nova Palmira e Passo Montenegro), na quarta e quinta rodada 2 postos (Linha Gonzaga e Nova Palmira). A simulação selecionada na primeira rodada é a que otimiza simultaneamente a maior quantidade de postos e o valor do coeficiente de Nash e será utilizada para realizar os experimentos de previsão para a BHRC.



Figura D1 – Coeficiente de Nash da melhor simulação, de acordo com o valor médio, em cada uma das cinco rodadas de 500 simulações realizadas

Fonte: Elaborado pelo autor.

A Tabela D1 apresenta os valores dos coeficientes de avaliação para o período de calibração do modelo. De acordo com o coeficiente de Nash, o posto Nova Palmira tem o melhor desempenho no período de calibração, enquanto o posto Barca do Caí obteve o pior desempenho. Analisando a Figura D2, que apresenta os hidrogramas e o gráfico de dispersão das vazões simuladas e observadas, verifica-se que nos postos Linha Gonzaga e Nova Palmira o modelo simula adequadamente as vazões baixas e intermediárias, enquanto as vazões altas são subestimadas.

Para os postos C. do Rio Cadeia, Barca do Caí e Passo Montenegro o modelo subestima as vazões de modo geral, ainda que consiga representar a variabilidade da bacia, o que também é evidenciado pelos valores de R nestas estações.

O resultado é semelhante para o período de validação (Tabela D2 e Figura D3), porém as variações dos coeficientes de avaliação indicam diminuição na capacidade de representação do modelo em alguns postos.

No posto Passo Linha Gonzaga a redução do coeficiente de Nash, KGE e R indicam piora no desempenho do modelo para o período de validação, enquanto a redução do RMSE e erro absoluto são positivos para o desempenho do modelo. Analisando os gráficos dos hidrogramas e de dispersão, nota-se que há aumento da dispersão para o período de validação. O resultado é semelhante para os postos Nova Palmira e C. do Rio Caldeia. Para o posto Barca do Caí os coeficientes de desempenho Nash, KGE, RMSE e EMA indicam melhora no desempenho do modelo para o período de validação enquanto que a redução do R indica o oposto. Avaliando graficamente o desempenho do posto, nota-se que há melhora na dispersão, porém, o modelo subestima as vazões em todas as faixas de vazão (das vazões baixas até os picos de cheia).

O resultado do coeficiente de Nash é melhor na estação Passo Montenegro os coeficientes KGE, RMSE e EMA também indicam melhora no desempenho do modelo em relação ao período de calibração e o oposto é indicado pela redução do R. O hidrograma e o gráfico de dispersão indicam que o modelo subestima as vazões também no período de calibração, porém, há uma melhora no desempenho quando comparado com o período de calibração.

É conveniente destacar que o período de validação (1094 dias) é maior do que o período de calibração (473 dias) de modo que as reduções nos coeficientes também estão associadas ao tamanho amostral e não somente às deficiências do modelo em representar as vazões para este período.

Posto	NSE	KGE	R	RMSE	EMA	EM
Linha Gonzaga	0,64	0,60	0,66	36,08	19,03	8,64
Nova Palmira	0,67	0,64	0,69	56,34	21,09	-6,72
C. do Rio Caldeia	0,47	0,31	0,62	26,98	13,12	-12,51
Barca do Caí	0,45	0,22	0,71	135,65	56,36	-51,06
Passo Montenegro	0,55	0,34	0,79	120,09	68,05	-67,42

Tabela D1 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE) e Erro Absoluto (absBIAS) para o período de calibração.

Fonte: Elaborado pelo autor.



Figura D2 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos fluviométricos da bacia do rio Caí no período de calibração.

Fonte: Elaborado pelo autor.

Posto	NSE	KGE	R	RMSE	EMA	EM
Linha Gonzaga	0,24	0,37	0,39	28,28	16,92	9,95
Nova Palmira	0,48	0,52	0,48	50,34	22,9	-0,27
C. do Rio Caldeia	0,43	0,27	0,60	20,99	10,03	-9,4
Barca do Caí	0,48	0,36	0,59	90,74	37,4	-22,47
Passo Montenegro	0,51	0,43	0,63	86,8	46,61	-39,33

Tabela D2 – Coeficiente de Nash (NSE), Kling-Gupta (KGE), Correlação (R), Raiz do Erro Quadrático Médio (RMSE) e Erro Absoluto (absBIAS) para o período de validação.

Fonte: Elaborado pelo autor.

Figura D3 – Série temporal e gráfico de dispersão de vazões simulada e observada para os postos fluviométricos da bacia do rio Caí no período de validação





Fonte: Elaborado pelo autor.

A respeito dos resultados apresentados da calibração e validação do modelo hidrológico, conclui-se que o modelo apresenta limitações para representar as vazões em todos os postos da bacia. O resultado da calibração foi melhor para a estação Linha Gonzaga enquanto para validação o resultado é menos elementar. Os coeficientes de avaliação indicam melhor desempenho do posto Passo Montenegro, contudo a análise gráfica dos hidrogramas ainda mostra desempenho satisfatório para os postos Linha Gonzaga e Nova Palmira.

## Comparação entre as previsões de vazão bruta e probabilísticas

A Figura D4 apresenta o resultado do coeficiente de correlação para todo o período. Um ponto que se destaca na correlação e nas demais métricas determinísticas é que as previsões probabilísticas apresentam comportamento muito semelhante entre si. Isto ocorre, pois, conforme definido na metodologia, para as previsões probabilísticas foi utilizado o percentil 50% como referência de previsão determinística e as FDPs parametrizadas não apresentam diferenças significativas nos percentis mais baixos. Para a BHRC os modelos BMA, CSG e GEV se diferenciam no extremo superior das distribuições de probabilidade. Em função da semelhança entre os modelos probabilísticos, estes não serão diferenciados na discussão deste item.

As previsões brutas dos ECMWF sem ajuste da vazão de saída apresentam os menores coeficientes de correlação, variando de 0,01 a -0,25 nos horizontes de tempo de 24 h a 120 h. As previsões probabilísticas sem ajuste da vazão de saída apresentam comportamento melhor, para o posto Linha Gonzaga a variação é de 0,64 (para o horizonte de 24 h) a 0,35 (para o horizonte de 120 h). O padrão é semelhante para os demais postos, sendo que no posto Nova Palmira a variação é de 0,61 a 0,31, Costa do rio Cadeia a variação é de 0,75 a 0,25, Barca do Caí é de 0,75 a 0,31 e na estação Passo Montenegro a correlação vai de 0,81 a 0,38 entre o horizonte de previsão de 24 h e 120 h.

Para as previsões brutas do ECMWF com a vazão de saída ajustada, a correlação é melhor do que a obtida utilizando a previsão bruta do ECMWF e sem ajuste da vazão de saída. As previsões processadas com a vazão de saída ajustada apresentaram o melhor resultado dentre todos os métodos testados. Todos os postos apresentam um mesmo padrão, no qual a correlação para o horizonte de 24 h é a menor, aumenta no horizonte de 48 h e declina entre os horizontes de 72 h e 120 h.

Figura D4 – Coeficiente de correlação (R) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste. Os postos estão ordenados da menor para maior área de drenagem.



Fonte: Elaborado pelo autor.

O valor do EMA em função do horizonte de previsão é mostrado na Figura D5. Com relação às previsões de vazão sem ajuste gerado com a previsão de precipitação bruta do ECMWF, o EMA aumenta em função do horizonte de previsão. Para as previsões probabilísticas sem ajuste da vazão de saída o resultado é melhor do que o anterior. Para as previsões com ajuste da vazão de saída geradas com a previsão de precipitação bruta do ECMWF o EMA é melhor do que no caso sem ajuste de saída. De modo geral há um aumento mais acentuado entre os horizontes de 24 h e 48 h, seguido de aumento suave entre 48 h e 120 h. As previsões processadas com a vazão de saída ajustada apresentaram o melhor resultado dentre todos os métodos testados. De modo geral o valor de EMA reduz entre 24 h e 48 h e em seguida aumenta gradualmente entre os horizontes de 48 h e 120 h. Figura D5 – Erro médio absoluto (EMA) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

O resultado do EM é mostrado na Figura D6. Com relação às previsões de vazão sem ajuste gerado com a previsão de precipitação bruta do ECMWF, o EM se afasta de zero em função do horizonte de previsão. Para as previsões processadas sem ajuste da vazão de saída, o EM do posto Linha Gonzaga se inicia em -5,1  $m^3s^{-1}$  e aumenta até 2,5  $m^3s^{-1}$  no horizonte de 120 h. Para o posto Nova Palmira o EM no horizonte de 24 h é 7,5  $m^3s^{-1}$  e aumenta até 16  $m^3s^{-1}$  no horizonte de 120 h. Também é observado aumento do EM entre os horizontes de 24 h e 120 h passando de 11  $m^3s^{-1}$  para 13  $m^3s^{-1}$  no posto Costa do rio Cadeia. No posto Barca do Caí o EM aumenta de 26  $m^3s^{-1}$  (horizonte de 24 h) para 44  $m^3s^{-1}$  entre os horizontes de 24 h e 120 h). O aumento no posto Passo Montenegro é de 45  $m^3s^{-1}$  para 63  $m^3s^{-1}$  entre os horizontes de 24 h e 120 h.

Para as previsões com ajuste da vazão de saída geradas com a previsão de precipitação bruta do ECMWF o EM do posto Linha Gonzaga apresenta pouca variação, sendo próximo de 2,5  $m^3 s^{-1}$ . No posto Nova Palmira a variação é pequena ficando entre 9  $m^3 s^{-1}$  no horizonte de 24 h e 7,5  $m^3 s^{-1}$  nos demais horizontes. A variação é maior no posto Costa do rio Cadeia que apresenta EM de 5  $m^3 s^{-1}$  no horizonte de 24 h, reduz até 2,5  $m^3 s^{-1}$  no horizonte de 72 h e mantém relativa estabilidade nos horizontes seguintes. No posto Barca do Caí o EM é de 15  $m^3 s^{-1}$  no horizonte de 24 h e reduz até 10  $m^3 s^{-1}$  no horizonte de 72 h, se mantendo estável nos horizontes seguintes. Para o posto Passo Montenegro o EM no horizonte de 24 h é 15  $m^3 s^{-1}$  e reduz nos horizontes seguintes, chegando a -5  $m^3 s^{-1}$  no horizonte de 120 h.

As previsões processadas com a vazão de saída ajustada apresentam aumento em função do horizonte de previsão. Passando de 2,6  $m^3 s^{-1}$  para 6  $m^3 s^{-1}$ , no posto Linha Gonzaga, de 6  $m^3 s^{-1}$  para 15,5  $m^3 s^{-1}$  no posto Nova Palmira, no posto Costa do rio Cadeia passa de 4  $m^3 s^{-1}$  para 9  $m^3 s^{-1}$ , para o posto Barca do Caí o EM varia de 2,5  $m^3 s^{-1}$  para 30  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h e no posto Passo Montenegro o EM varia entre 5  $m^3 s^{-1}$  e 40  $m^3 s^{-1}$  em todos os casos entre os horizontes entre 24 h e 120 h. Figura D6 – Erro médio (EM) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) calculada com a mediana do conjunto, processada com os modelos BMA (azul), GEV (verde) e CSG (laranja) calculada com o quantil de probabilidade de 50% de excedência. A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

A Figura D7 apresenta o resultado do Brier Score, considerando como limiar de cheia o percentil 75% da vazão, tanto para as previsões brutas do ECMWF, quanto para previsões geradas a partir dos quantis de precipitação e considerando a vazão de saída sem ajuste e ajustada.

Primeiramente serão analisadas as previsões geradas utilizando as previsões de precipitação brutas do ECMWF sem ajuste da vazão de saída. Para os postos Linha Gonzaga, Nova Palmira, Costa do rio Cadeia e Passo Montenegro a variação do Brier Score em função do horizonte de previsão é baixa, sendo próxima de 0,70 para Linha Gonzaga, 0,63 para Nova Palmira, de 0,19 a 0,22 no posto Costa do Rio Cadeia e no posto Passo Montenegro varia entre 0,22 e 0,20. Para estação Barca do Caí o Brier Score aumenta em função do horizonte de previsão passando de 0,17 no horizonte de 24 h para 0,35 no horizonte de 120 h.

Para as previsões processadas sem ajuste da vazão de saída, o Brier Score também apresenta pouca variação em função do horizonte de previsão nas estações Linha Gonzaga, Nova Palmira, Costa do rio Cadeia e Passo Montenegro. Para o posto Linha Gonzaga o processamento com os modelos GEV e CSG varia entre 0,30 (horizonte de 24 h) e 0,20 (horizonte de 120 h). No posto Nova Palmira as previsões processadas com os modelos GEV e CSG é praticamente estável e, quando processada com o modelo BMA, varia entre 0,12 (horizonte de 24 h) e 0,25 (horizonte de 120 h). O Brier Score no posto Costa do rio Cadeia tem variação pequena no processamento com o modelo GEV e CSG que fica entre 0,19 e 0,21 e para o modelo BMA varia entre 0,20 (horizonte de 24 h) e 0,24 (horizonte de 120 h). No posto Barca do Caí o Brier Score varia de 0,15 a 0,20 entre os horizontes de 24 h e 120 h no processamento com os modelos GEV e CSG enquanto no processamento com o modelo BMA varia de 0,17 para 0,24 entre os horizontes de 24 h e 120 h. Para o posto Passo Montenegro o Brier Score do processamento com os modelos GEV e CSG varia entre 0,17 e 0,20 e para o processamento com modelo BMA varia entre 0,18 e 0,24 em ambos os casos entre os horizontes de 24 h e 120 h.

As previsões geradas utilizando as previsões de precipitação brutas do ECMWF com ajuste da vazão de saída apresentam aumento do Brier Score em função do horizonte de previsão. Para o posto Linha Gonzaga a previsão com horizonte de 24 h apresenta Brier Score de 0,13, que aumenta até 0,30 no horizonte de previsão de 120 h. No posto Nova Palmira o aumento ocorre entre os horizontes de 24 h e 96 h, passando de 0,15 para 0,31. A variação do posto Costa do rio Cadeia é de 0,16, no horizonte de

24 h, para 0,30 no horizonte de 120 h. Para o posto Barca do Caí o Brier Score passa de 0,15 no horizonte de 24 h para 0,32 no horizonte de 120 h. O Brier Score do posto Passo Montenegro vai de 0,18 no horizonte de 24 h para 0,33 no horizonte de 120 h.

Para as previsões de precipitação processadas e com a vazão de saída ajustada, o comportamento dos modelos é muito semelhante sendo que o modelo BMA apresenta resultado inferior (Brier Score mais alto) do que os modelos GEV e CSG. Para o posto Linha Gonzaga o Brier Score apresenta pouca variação em função do horizonte de previsão, variando entre 0,08 e 0,10. O Brier Score do posto Nova Palmira reduz entre os horizontes de 24 h e 48 h, passando de 0,12 para 0,08 e nos demais horizontes não há variação relevante, se mantendo entre 0,08 e 0,09. O comportamento do posto Costa do rio Cadeia também apresenta redução do Brier Score entre os horizontes de 24 h e 48 h, passando de 0,10 para previsões com os modelos GEV e CSG (BMA) nos demais horizontes o Brier Score varia entre 0,05 e 0,10 (0,10 e 0,13). O Brier Score reduz em função do horizonte de previsão passando de 0,13 (0,14) para 0,06 (0,09) para previsões com os modelos GEV e CSG (BMA) no horizonte de 120 h. O posto Passo Montenegro apresenta variação positiva entre os horizontes de 24 h e 48 h, com o Brier Score passando de 0,15 (0,16) para 0,17 (0,19) e em seguida reduzindo para 0,12 (0,15) nos horizontes seguintes.

Figura D7 – *Brier Score* (BS) considerando como limiar de cheia o percentil 75% da vazão e vazão observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

A Figura D8 apresenta o *Continuous Ranked Probability Score* tanto para as previsões brutas do ECMWF, quanto para previsões geradas a partir dos quantis de precipitação e considerando a vazão de saída sem ajuste e ajustada.

Para as previsões geradas utilizando as previsões de precipitação brutas do ECMWF sem ajuste da vazão de saída, o comportamento é semelhante tanto entre os diferentes tipos de previsões quanto em termos de evolução do coeficiente ao longo dos horizontes de previsão. Para o posto Linha Gonzaga, o CRPS para previsões do ECMWF varia entre 12 e 13  $m^3s^{-1}$ . No posto Nova Palmira o CRPS varia entre 24  $m^3s^{-1}$  e 25  $m^3s^{-1}$  entre os horizontes de 24 h e 120 h. Para o posto Costa do rio Cadeia o CRPS varia entre 13  $m^3s^{-1}$  e 14  $m^3s^{-1}$ , no posto Barca do Caí a variação do CRPS é de 42  $m^3s^{-1}$  no horizonte de 24 h para 45  $m^3s^{-1}$  no horizonte de 120 h e no posto Passo Montenegro o CRPS aumenta de 54  $m^3s^{-1}$  no horizonte de 24 h para 58  $m^3s^{-1}$  no horizonte de 120 h.

Para as previsões de precipitação processadas e com a vazão de saída sem ajuste, o CRPS possui, em alguns casos, aumento mais pronunciado em função do horizonte de previsão. Para o posto Linha Gonzaga o CRPS não apresenta variação relevante, ficando próximo de 11  $m^3 s^{-1}$ , no posto Nova Palmira a variação é maior com o CRPS variando de 18  $m^3 s^{-1}$  para 24  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h. Para o posto Costa do rio Cadeia o CRPS aumenta de 10  $m^3 s^{-1}$ para 13  $m^3 s^{-1}$  entre os horizontes de 24 h e 120 h. O aumento no posto Barca do Caí é mais pronunciado sendo o CRPS igual a 30  $m^3 s^{-1}$  no horizonte de 24 h e chegando a 44  $m^3 s^{-1}$  no horizonte de 120 h. no posto Passo Montenegro o CRPS no horizonte de 24 h é de 37  $m^3 s^{-1}$  e aumenta até 56  $m^3 s^{-1}$  no horizonte de 120 h.

As previsões geradas utilizando as previsões de precipitação brutas do ECMWF com ajuste da vazão de saída apresentam diferenças em relação ao observado quando não é feito o ajuste da vazão de saída. Para o posto Linha Gonzaga o CRPS aumenta em função do horizonte de previsão, passando de 9  $m^3s^{-1}$  para 12  $m^3s^{-1}$  entre os horizontes de 24 h e 120 h, no posto Nova Palmira a variação é de 21  $m^3s^{-1}$  para o horizonte de 24 h e fica em torno de 27  $m^3s^{-1}$  para o horizonte de 120 h. No posto Costa do rio Cadeia o CRPS aumenta entre os horizontes de 24 h e 96 h passando de 10  $m^3s^{-1}$  para 19  $m^3s^{-1}$  e reduz para 18  $m^3s^{-1}$  no horizonte de 120 h. Para o posto Barca do Caí o CRPS de 24 h é 31  $m^3s^{-1}$  e aumenta até 51  $m^3s^{-1}$  no horizonte de 120
h, o resultado do posto Passo Montenegro também apresenta aumento saindo de 41  $m^3 s^{-1}$  no horizonte de 24 h e chegando e a 67  $m^3 s^{-1}$  no horizonte de 120 h.

Assim como nas previsões sem ajuste da vazão de saída, as previsões geradas a partir de previsões de precipitação processadas e com a vazão de saída ajustada apresentam comportamento semelhante entre os modelos. Para o posto Linha Gonzaga há redução do CRPS entre 24 h e 48 h passando de 7  $m^3s^{-1}$  para  $5m^3s^{-1}$ seguido por um pequeno aumento e chegando a 6  $m^3s^{-1}$  no horizonte de 120 h. O comportamento é similar no posto Nova Palmira, no qual o CRPS reduz de 16  $m^3s^{-1}$  para 9  $m^3s^{-1}$ , entre os horizontes de previsão de 24 h e 48 h, e aumenta até 12  $m^3s^{-1}$  no horizonte de 120 h. Para o posto Costa do rio Cadeia o CRPS oscila entre 5  $m^3s^{-1}$  (no horizonte de 120 h). Para o posto Barca do Caí o CRPS no horizonte de previsão de 24 h é 25  $m^3s^{-1}$ , reduz para 16  $m^3s^{-1}$  no horizonte de 48 h e aumenta gradualmente até 22  $m^3s^{-1}$  no horizonte de 120 h. No posto Passo Montenegro o CRPS para o horizonte de 24 h é 27  $m^3s^{-1}$  o CRPS reduz para 22  $m^3s^{-1}$  no horizonte de 48 h e aumenta para 30  $m^3s^{-1}$  no horizonte de 120 h.

Figura D8 – *Continuous Ranked Probability Score* (CRPS) entre a vazão prevista e observada em função dos horizontes de previsão (24 h a 120 h) para a previsão bruta do ECMWF (preto) e processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A primeira coluna apresenta as previsões com a vazão ajustada e a segunda coluna as previsões sem ajuste.



Fonte: Elaborado pelo autor.

A curva ROC para previsões de vazão é mostrada na Figura D9. De acordo com o gráfico as previsões de vazão sem ajuste da vazão de saída geradas a partir da previsão de precipitação bruta do ECMWF possui a pior capacidade de discriminação de eventos. O ajuste da vazão de saída isoladamente promove alguma melhora na capacidade de discriminação. Da mesma forma, o processamento da previsão de precipitação com os modelos BMA, GEV e CSG também melhoram a capacidade de discriminação de eventos, sendo que os modelos GEV e CSG se destacam mais do que o modelo BMA. Contudo o melhor desempenho ocorre quando as previsões de precipitação são processadas com um dos modelos propostos e a vazão de saída do modelo hidrológico é ajustada, ou seja, a combinação do processamento da precipitação associada com o ajuste do modelo apresenta a melhor capacidade de discriminação de eventos.

Figura D9 – Curva ROC para previsões de vazão, nas estações de monitoramento da bacia (linhas) em diferentes horizontes de tempo (colunas). As linhas tracejadas (sólidas) se referem às previsões sem ajuste da vazão (ajustada).



Fonte: Elaborado pelo autor.

Os gráficos mostrados entre a figura D10 e figura D13 apresentam o diagrama de confiabilidade da previsão de vazão utilizando a precipitação bruta do ECMWF e com os quantis de precipitação dos modelos probabilísticos BMA, GEV e CSG. Em ambos os casos é apresentada apenas a modelagem com a vazão de saída ajustada e considerando o percentil 75% da vazão como limiar para ocorrência de eventos. O resultado para as vazões sem ajustes são, em todas as condições, piores do que com as vazões ajustadas e por brevidade as figuras foram omitidas.

De modo geral, os resultados para a BHRC mostram comportamento muito irregular. Este tipo de comportamento está associado com a concentração excessiva dos membros do conjunto, de modo que a previsão se comporta de modo similar a uma previsão determinística de modo que o resultado é afetado pela concentração das amostras nas classes extremas.

Figura D10 – Diagrama de Confiabilidade (*Reliability Diagram*) da estação Estrada do Cunha utilizando o percentil de 75% como limiar para ocorrência de eventos. O diagrama é composto pela curva de calibração (acima) e refinamento da distribuição (abaixo) para previsões com horizontes de 24 h a 120 h, sendo representada a previsão bruta (preto), processada com os modelos BMA (azul), GEV (verde) e CSG (laranja). A linha identidade da curva de calibração indica o comportamento desejado.



Fonte: Elaborado pelo autor.

Figura D11 - Mesmo que na figura D10, mas para a estação São Luís do Paraitinga.



Fonte: Elaborado pelo autor.



Figura D12 - Mesmo que na figura D10, mas para aestação Ponte Alta I.

Fonte: Elaborado pelo autor.





Fonte: Elaborado pelo autor.



Figura D14 – Mesmo que na figura D10, mas para a estação Passo Montenegro.

Fonte: Elaborado pelo autor.

Os *rank histograms* para a previsão de vazão gerada com o modelo hidrológico alimentado com as previsões brutas do ECMWF para horizontes de previsão de 24 h a 120 h, são apresentados na Figura D15. Para as previsões sem processamento, os *rank histograms* de todos os horizontes de tempo apresentam formato de "U". Este tipo de formato indica concentração excessiva dos membros do conjunto, pois as observações se posicionam frequentemente nas classes extremas do histograma. A concentração excessiva implica em excesso de confiança na previsão, cujos membros indicam valores semelhantes entre si. O resultado segue o mesmo padrão em todas as estações de monitoramento da bacia e em todos os horizontes de tempo de previsão.



Figura D15 – *Rank Histogram* para previsões de vazão da BRPS para diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.

Fonte: Elaborado pelo autor.

Para permitir a comparação entre os *rank histograms* das previsões brutas com os PIT *histograms* das previsões processadas, foi utilizado o mesmo número de classes (10). A Figura D16 apresenta o resultado para a previsão de vazão com o modelo hidrológico alimentado com a chuva processada utilizando os modelos BMA, GEV e CSG. Para as previsões geradas com o modelo BMA, o histograma apresenta um padrão em que as observações se concentram nos percentis mais altos, indicando assim que as previsões subestimam a vazão observada. Para os modelos GEV e CSG, as observações apresentam melhor distribuição entre os percentis.

Nota-se que os histogramas apresentam um padrão do tipo "U" para o resultado do modelo BMA. O resultado com os modelos GEV e CSG apresentam comportamento semelhante entre si. Neste padrão há uma concentração de observações na primeira classe, indicando que há um grande número de casos em que as observações são menores que a menor previsão, combinado com um padrão de "rampa", com as observações se posicionando majoritariamente entre a probabilidade intermediária à alta. O resultado do PIT histogram está longe do padrão ideal, contudo, comparado com as previsões brutas do ECMWF, há melhora na qualidade da previsão de vazão (especificamente na dispersão dos membros do conjunto) utilizando a precipitação processada com o modelo GEV e CSG. Para as previsões com horizonte de 24 h as observações se concentram no primeiro percentil, ou seja, as observações são frequentemente menores que a previsão e nas três classes mais altas indicando que parte das observações estão frequentemente posicionadas entre os percentis mais altos. Este gráfico indica que o processamento com a GEV e CSG promoveu alguma melhora na distribuição das previsões, contudo, as previsões com os modelos GEV e CSG, assim como as previsões sem processamento, apresentam concentração dos membros.

Figura D16 – PIT *histogram* para previsões de precipitação processadas da BHAT em diferentes horizontes de tempo. A linha tracejada indica a frequência relativa ideal para que os membros sejam equiprováveis.



Fonte: Elaborado pelo autor.

## Hidrogramas de previsão da vazão máxima registrada

Este item é dedicado à avaliação dos hidrogramas previstos para a máxima registrada em cada um dos postos de monitoramento fluviométrico da bacia. A Tabela D3 apresenta a data e a vazão registrada na máxima em cada posto fluviométrico utilizado. Neste caso, os dias da vazão máxima são próximos para os postos Linha Gonzaga, Costa do Rio Cadeia e Passo Montenegro, indicando que a vazão máxima está associada ao mesmo evento de precipitação nestes casos.

Posto de monitoramento	Data da máxima	Vazão registrada ( $m^3 s^{-1}$ )
Linha Gonzaga	04/09/2018	219,0
Nova Palmira	04/05/2019	501,8
Costa do Rio Cadeia	02/09/2018	172,4
Barca do Caí	25/08/2018	764,9
Passo Montenegro	05/09/2018	746,1

Tabela D3 – Data e valor da vazão máxima registrada no período de estudo em cada posto de monitoramento

Fonte: Elaborado pelo autor.

Os hidrogramas previstos e observados para o posto Linha Gonzaga são mostrados na Figura D17. Para a previsão bruta do ECMWF, com a vazão sem ajuste e ajustada, há concentração dos membros do conjunto sendo que apenas um membro se diferencia dos demais membros. Em nenhum caso a previsão consegue representar as vazões previstas.

Para a previsão processada com o modelo BMA, o resultado da previsão sem ajuste da vazão de saída segue padrão semelhante ao anterior e a previsão não representa a vazão observada para o período. O ajuste da vazão de saída indica melhora discreta na previsão para as previsões com 96 h e 120 h de antecedência. Ainda assim, as vazões previstas subestimam a vazão observada e há concentração dos membros.

O processamento com a GEV apresenta melhora no espalhamento das previsões, porém, para o caso da vazão sem ajuste, as previsões não representam o hidrograma observado. Quando a vazão de saída é ajustada, há melhora na representação dos hidrogramas em todos os horizontes de previsão. Contudo, para os horizontes de previsão de 24 h e 48 h de antecedência todos os quantis ficam abaixo da vazão observada, sendo que para o horizonte de 72 h a vazão observada se localiza entre os quantis de 85% e 95% e para os horizontes de 96 h e 120 h a vazão observada está situada entre os quantis de 75% e 85%. O resultado para o processamento CSG segue o mesmo padrão do modelo anterior.



Figura D17 – Mesmo que na figura D10, mas para a estação Linha Gonzaga

Fonte: Elaborado pelo autor.

A Figura D18 apresenta os hidrogramas previstos e observados para o posto Nova Palmira. Para a previsão bruta do ECMWF, com a vazão sem ajuste e ajustada, há dificuldade em representar as vazões observadas em todos os horizontes de previsão.

Para a previsão processada com o modelo BMA, a previsão sem ajuste da vazão de saída também não representa adequadamente a vazão de pico observada. O ajuste da vazão de saída melhora a previsão para os horizontes de 48 h a 120 h de antecedência. Ainda assim as vazões previstas subestimam a vazão observada e há concentração dos membros.

O processamento com a GEV apresenta melhora no espalhamento das previsões, porém, para o caso da vazão sem ajuste, as previsões não representam o hidrograma observado. Quando a vazão de saída é ajustada, há melhora na representação dos hidrogramas para os horizontes de previsão de 48 h a 120 h de antecedência. Para as previsões com 48 h e 72 h de antecedência, a vazão de pico está entre os quantis de previsão de 75% e 85% e para as previsões com 96 h e 120 h de antecedência o observado se localiza entre os quantis de 85% e 95%. O resultado com o processamento com a CSG é semelhante ao anterior tanto para previsões sem e com ajuste da vazão de saída e em todos os horizontes de previsão.



Figura D18 – Mesmo que na figura D10, mas para a estação Nova Palmira.

Fonte: Elaborado pelo autor.

Os resultados do posto Costa do Rio Cadeia são mostrados na Figura D19. Para a previsão bruta do ECMWF, com a vazão sem ajuste e ajustada, há concentração dos membros do conjunto sendo que apenas um membro se diferencia dos demais membros. Em nenhum caso a previsão consegue representar as vazões previstas.

Para a previsão processada com o modelo BMA, a previsão sem ajuste da vazão de saída também não representa adequadamente a vazão de pico observada. O ajuste da vazão de saída melhora a previsão para os horizontes de 48 h a 120 h de antecedência, porém, assim como nos postos anteriores, as vazões previstas subestimam a vazão observada e há concentração dos membros.

O processamento com a GEV apresenta melhora no espalhamento das previsões, porém, para o caso da vazão sem ajuste, as previsões não representam o hidrograma observado. Quando a vazão de saída é ajustada, há melhora na representação dos hidrogramas. Para as previsões com 24 h a 72 h de antecedência, a vazão de pico está entre os quantis de previsão de 85% e 95% e para as previsões com 96 h e 120 h de antecedência o observado se localiza entre os quantis de 75% e 85%. Tanto para previsões sem ajuste quanto para as previsões com ajuste da vazão de saída e em todos os horizontes de previsão o resultado do processamento com a CSG é semelhante ao anterior.



Figura D19 – Mesmo que na figura D10, mas para a estação Costa do Rio Cadeia.

Fonte: Elaborado pelo autor.

A Figura D20 apresenta os resultados do posto Barca do Caí. Para a previsão bruta do ECMWF, com a vazão sem ajuste e ajustada, há concentração dos membros do

conjunto sendo que apenas um membro se diferencia dos demais membros. Em nenhum caso a previsão consegue representar as vazões previstas.

Para a previsão processada com o modelo BMA, a previsão sem ajuste da vazão de saída também não representa adequadamente a vazão de pico observada. O ajuste da vazão de saída melhora a previsão para os horizontes de 48 h a 120 h de antecedência, porém, assim como nos postos anteriores, as vazões previstas subestimam a vazão observada e há concentração dos membros.

O processamento com a GEV apresenta melhora no espalhamento das previsões, porém, para o caso da vazão sem ajuste, as previsões não representam o hidrograma observado. Quando a vazão de saída é ajustada, há melhora na representação dos hidrogramas. Para a previsão com 48 h de antecipação a vazão de pico está entre os quantis de previsão de 85% e 95%, para previsão com 72 h de antecedência a vazão observada se localiza entre os quantis de 75% e 85%, para previsões com 96 h e 120 h de antecedência, a vazão observada está entre os quantis 45% e 55%.



Figura D20 – Mesmo que na figura D10, mas para a estação Barca do Caí.

Fonte: Elaborado pelo autor.