

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

CORREÇÃO DE VIÉS DE DADOS DIÁRIOS DE PRECIPITAÇÃO DO WRF

Karollyn Larissa de Quadros¹; Maria Fernanda Dames de Lima²; Danieli Mara Ferreira³; José Eduardo Gonçalves⁴; Michael Mannich⁵; Rafael Toshio Inouye⁶ & Reinaldo Silveira⁷

Abstract: Weather forecasting systems are essential for ensuring the quality of hydrometeorological analyses and models. This study evaluated the performance of the Weather Research and Forecasting (WRF) model in daily precipitation forecasting for the Jaguari-Buenópolis basin (São Paulo, Brazil) from 2019, to 2025. An initial comparison of the model's seven forecast lead times showed that the same-day forecast (h_0) was the most accurate, with an NSE of 0.72, RMSE of 44.01 mm, and bias of 2.8%. Hits and misses in predicting rainy and dry days were analyzed, with accuracy reaching 94.2% in winter and 74.6% in summer. Recall was higher in summer (90.8%) and lower in winter (67.3%), indicating greater sensitivity of the model during the rainy season. Five bias correction methods (Offset, LOC, QMAP log, Weibull, and Gamma) were applied to the h_0 horizon, stratified by season. The QMAP method showed the best performance, significantly reducing bias, especially in spring (from -0.381 to 0.058) and overall (from 0.106 to 0.020). After correction, there was an increase in accuracy (up to 3.0%) and precision (up to 12.6%), although a slight reduction in recall was observed. QMAP and Weibull stood out for improving the reliability of rainfall forecasts, particularly in summer and spring.

Resumo: Sistemas de previsão de tempo são essenciais para garantir a qualidade de análises e modelos hidrometeorológicos. Este estudo avaliou o desempenho do modelo Weather Research and Forecasting (WRF) na previsão diária de precipitação para a bacia Jaguari-Buenópolis (SP) no período de 2019 a 2025. Inicialmente, foi realizada a comparação dos sete horizontes de previsão do modelo, sendo o horizonte do mesmo dia (h_0) o mais preciso, com NSE de 0,72, RMSE de 44,01 mm e viés de 2,8%. Foram analisados os acertos e erros do modelo em prever dias com e sem chuva, com destaque para a acurácia de 94,2% no inverno e 74,6% no verão, enquanto o recall foi maior no verão (90,8%) e menor no inverno (67,3%), indicando maior sensibilidade do modelo durante o período chuvoso. Aplicaram-se cinco métodos de correção de viés (Offset, LOC, QMAP log, Weibull e Gamma) sobre o horizonte h_0 , separados por estação do ano. O método QMAP apresentou os melhores resultados, reduzindo significativamente o viés, especialmente na primavera (de -0,381 para 0,058) e no total (de 0,106 para 0,020). Após as correções, houve aumento na taxa de acerto (até 3,0%) e na precisão (até 12,6%), embora com leve redução no recall. Os métodos QMAP e Weibull destacam-se por melhorar a confiabilidade da previsão de chuva, principalmente no verão e na primavera.

Palavras-Chave – Previsão hidrológica; Previsão meteorológica por conjunto; Bacias PCJ

¹⁾ Simepar / UFPR - karollyn.quadros@simepar.br / karollyn@ufpr.br

²⁾ Simepar / UFPR - maria.dames@simepar.br / mfdames@ufpr.br

³⁾ Simepar - danieli.ferreira@simepar.br

⁴⁾ Simepar - jose.eduardo@simepar.br

⁵⁾ UFPR - mannich@ufpr.br

⁶⁾ Simepar - rafael.toshio@simepar.br

⁷⁾ Simepar - reinaldo.silveira@simepar.br

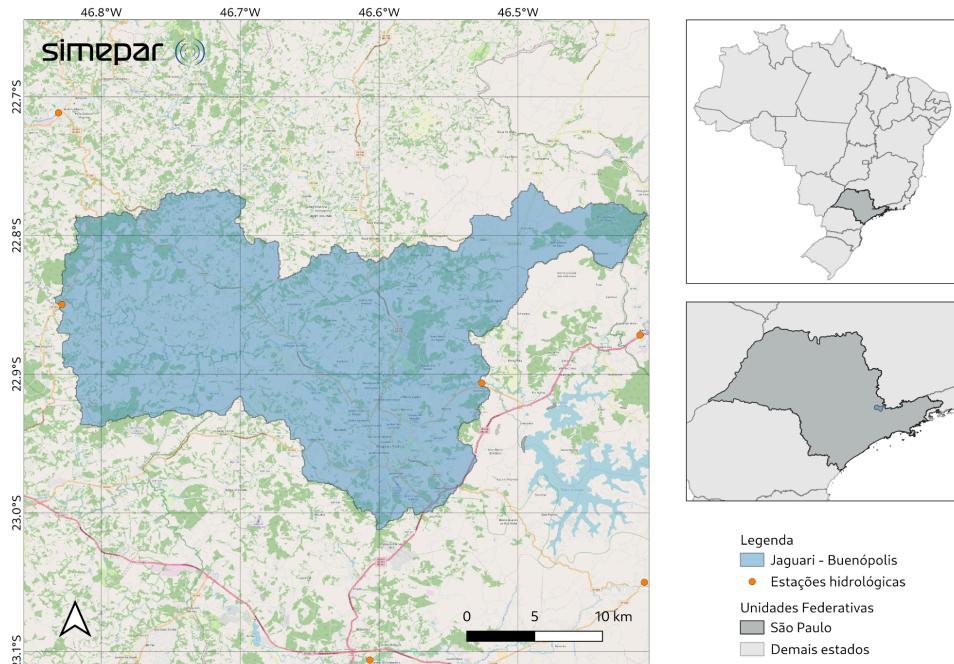
INTRODUÇÃO

A previsão hidrológica é uma ferramenta essencial para otimizar o uso dos recursos hídricos e mitigar os impactos de eventos extremos, como inundações e secas. Em regiões com intensos conflitos pelo uso da água, sistemas operacionais de previsão hidrológica atuam oferecendo suporte técnico para a tomada de decisões. Este trabalho visa aprimorar os dados de previsão de precipitação do Sistema de Previsão Hidrometeorológica das Bacias Hidrográficas dos Rios Piracicaba, Capivari e Jundiaí - (SPHM-PCJ) desenvolvido pelo Sistema de Tecnologia e Monitoramento Ambiental do Paraná (Simepar) em conjunto com os Comitês das Bacias Hidrográficas dos Rios Piracicaba, Capivari e Jundiaí (Comitês PCJ). Para isso, foram aplicadas técnicas de correção de viés do modelo WRF, através de dados de estações meteorológicas na bacia hidrográfica do rio Jaguari - Buenópolis.

MATERIAIS E MÉTODOS

A figura 1 apresenta a localização área de estudos, que consiste na bacia hidrográfica Jaguari-Buenópolis. Foram utilizados dados horários de precipitação observada nas estações meteorológicas e dados de previsão do Weather Research and Forecasting (WRF) versão 4.5 (Skamarok). O modelo meteorológico é executado pelo Simepar com resolução espacial de 5 km e saídas horárias, suas parametrizações incluem a de Morrison como microfísica, New Tiedke como de cumulus, esquema da camada limite planetária da universidade de Yonsei (YSU) e radiação RRTMG. O período analisado foi de 24-01-2019 a 24-01-2025. Foi obtida a média espacial dos dados para a bacia em escala de tempo horário.

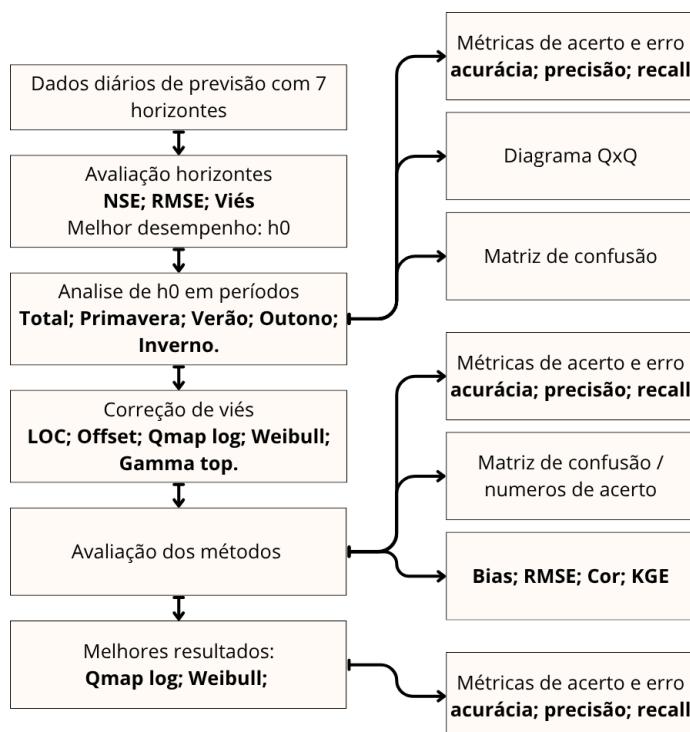
Figura 1 – Bacia Jaguari - Buenópolis – bacia de estudo



Conforme o fluxograma da figura 2, foram utilizadas métricas baseadas na matriz de confusão para avaliar o desempenho do modelo na previsão da ocorrência de chuva. As principais métricas consideradas foram: acurácia, precisão e recall. A acurácia representa, como um todo, a proporção de acertos do modelo (dias com e sem chuva) em relação ao total de dias analisados, ou seja, a menor distância da referência. Enquanto a precisão mede o quanto o modelo foi assertivo ao

prever chuva, ou seja, em relação ao par de eventos certos, quantos dos dias previstos com chuva realmente apresentaram o evento. A acurácia representa a proporção de acertos do modelo (tanto em dias com quanto sem chuva) em relação ao total de dias analisados. Já a precisão mede o quanto o modelo foi assertivo ao prever chuva, ou seja, quantos dos dias previstos com chuva realmente apresentaram o evento (CONGALTON, 2009). Por fim, o recall (ou sensibilidade) indica a capacidade do modelo em identificar corretamente os dias chuvosos, ou seja, quantos dos dias com chuva real foram efetivamente previstos como tal. Essas métricas são especialmente úteis para avaliar o desempenho em cenários binários (chuva ou não chuva), permitindo entender não apenas o número total de acertos, mas também a qualidade das previsões positivas, que são mais relevantes do ponto de vista operacional.

Figura 2 – Fluxograma do estudo



Para avaliar o desempenho sazonal do modelo, as previsões foram analisadas separadamente para cada estação do ano. As estações foram definidas conforme a climatologia convencional do hemisfério sul, sendo: verão (dezembro, janeiro e fevereiro — DJF), outono (março, abril e maio — MAM), inverno (junho, julho e agosto — JJA) e primavera (setembro, outubro e novembro — SON). A partir dessas divisões, foram construídas matrizes de confusão específicas para cada estação, relacionando a ocorrência observada de chuva (chuva ou não chuva) com a previsão correspondente feita pelo modelo WRF. Essa abordagem permite quantificar a habilidade do modelo em diferentes períodos do ano, destacando possíveis variações sazonais no desempenho, uma vez que estudos anteriores já apontam sensibilidade sazonal significativa do WRF (Bughici et al., 2019). As matrizes possibilitam o cálculo de métricas como acurácia, precisão e recall, essenciais para compreender a capacidade do modelo em prever corretamente tanto eventos de chuva quanto a ausência deles.

Os métodos de correção aplicados são (i) offset, ou correção aditiva, em que o valor corrigido de previsão é igual ao valor de previsão menos um offset, esse offset é calculado como a média dos valores previstos - observados (de 0.9 para o verão, a -0.381 para a primavera). (ii) correção por regressão linear em linha de correlação orgânica (LOC), que minimiza a soma das

áreas de triângulos retângulos formados por linhas horizontais e verticais estendendo-se das observações até a linha ajustada, a linha ajustada é uma função de primeira ordem entre os dados, a função possui dois parâmetros ajustados: a inclinação (de -0,85 para o verão a 0,37 para o outono) e o intercepto (correspondente a 0,99 e 0,87, respectivamente), para a correção os dados foram transformados em log. A correção por percentis ou quantile mapping ajusta a distribuição da variável prevista para que tenha a mesma distribuição dos dados observados, a distribuição pode ser feita por dados empíricos, os próprios dados previstos, ou por um ajuste desses dados a uma distribuição que melhor representa esses dados observados. Para a correção pela distribuição de dados empíricos foi aplicado o $\ln(x + 1)$ nos dados para aproximar os dados extremos à curva de distribuição. A correção por percentis também foi aplicada a curvas de distribuição Weibull. Os parâmetros da distribuição Weibull estimados para os dados modelados apresentaram valores na faixa de 0,6 a 1 para o parâmetro de forma (shape), de 5,7 a 10,6 para o parâmetro de escala (scale), e o parâmetro de forma para os dados observados ficou em torno de 0,69. Também foi aplicado modelo Gamma focando apenas no tercil superior dos dados, ou seja, os 30% maiores valores da série para focar em acertar os máximos de precipitação.

Apesar das correções valores abaixo do limiar de 1 mm foram mantidos na série, então considerando que o foco é no verão, os valores de previsão de chuva abaixo desse limiar não foram corrigidos. Além disso, o valor máximo para as séries corrigidas foi limitado ao valor máximo observado da série.

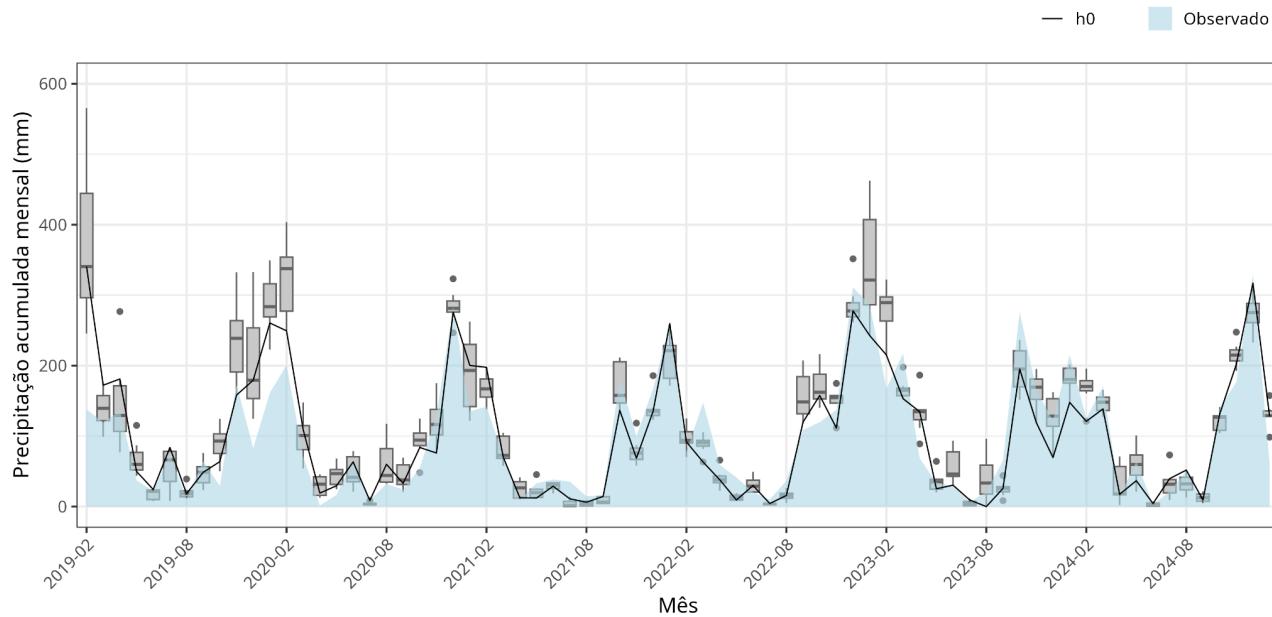
RESULTADOS

Caracterização do viés

Para uma análise visual e comparação entre os valores observados de precipitação e as previsões geradas pelo modelo WRF foi gerado um gráfico com valores acumulados mensais (figura 3) para diferentes horizontes de previsão, ao longo do período de 01/02/2019 a 31/12/2024 (meses fechados). A hachura azul e linha preta representam a precipitação observada e a previsão no horizonte h0 (gerada no mesmo dia), respectivamente, enquanto os box plots indicam a distribuição das previsões do modelo para cada horizonte de previsão (h0 incluso), de 1 a 7 dias. Cada boxplot reflete a dispersão dos valores de previsão para o respectivo horizonte, com a caixa representando o intervalo interquartílico (IQR) e a linha central indicando a mediana das previsões. Os "bigodes" dos boxplots abrangem os valores dentro de 1,5 vezes o IQR, e os pontos fora dessa faixa são considerados outliers. A análise permite observar como as previsões variam ao longo do tempo e em função dos diferentes horizontes de previsão, destacando os momentos de maior incerteza nas previsões, especialmente em horizontes mais longos.

A variabilidade das previsões é menor durante os meses menos chuvosos. Esse comportamento reflete uma menor incerteza nas previsões de precipitação, uma vez que a menor quantidade de chuva torna as previsões mais estáveis. Com o início do período úmido, observa-se um aumento significativo na variabilidade dos valores de precipitação, o que é esperado devido à maior intensidade e frequência das chuvas. A representação do h0, em linha preta, mostra que nem sempre o valor previsto mais próximo do observado é do h0, mas é o que apresenta melhor valores mais próximos do observado são previstos pelo menor horizonte, contudo o h0 é o horizonte que apresenta melhores resultados na tabela 1.

Figura 3 – hidrograma – série de precipitação observada e dos horizontes previstos



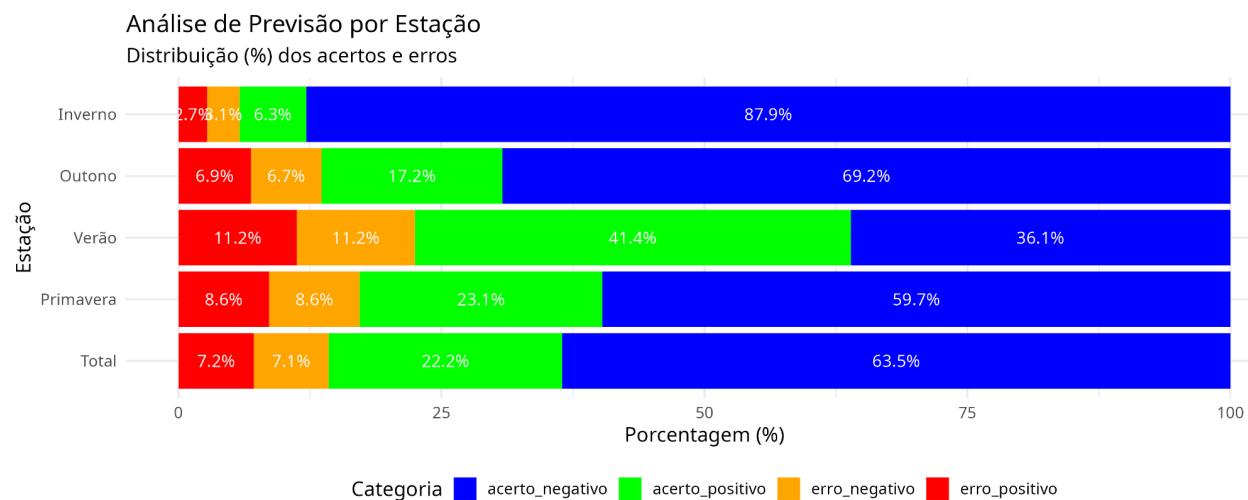
A tabela 1 apresenta os indicadores de desempenho do modelo WRF para diferentes horizontes de previsão (h0 a h6), comparando os valores simulados de precipitação com os observados. O horizonte h0, que representa a previsão para o mesmo dia, apresentou o melhor desempenho com NSE de 0,72, RMSE de 44,01 mm e viés de 2,8%, indicando boa eficiência e baixo viés. Os horizontes seguintes mostraram queda progressiva na performance. A partir de h3, o modelo apresenta viés elevado, acima de 17%, e eficiência (NSE) abaixo de 0,5. O pior desempenho foi observado no h6, com NSE de 0,30, RMSE de 69,91 mm e viés de 28,8%, evidenciando menor confiabilidade das previsões a médio prazo. O horizonte h2 apresentou desempenho semelhante ao h0, com NSE de 0,72 e RMSE levemente maior, o que pode indicar estabilidade pontual no modelo para previsões com dois dias de antecedência.

Tabela 1 – Comparação entre cada horizonte e o dado observado - avaliação de NSE, RMSE e Viés

Horizonte	NSE	RMSE	VIÉS
h0	0,72	44,01	2.8%
h1	0,53	56,98	8.4%
h2	0,72	44,46	3.4%
h3	0,49	59,53	18.5%
h4	0,31	69,39	17.8%
h5	0,46	61,22	18.4%
h6	0,3	69,91	28.8%

O modelo WRF é significativamente sensível à sazonalidade (BUGHICI et al. 2019) para analisar melhor seu desempenho sazonal foi elaborada uma matriz de confusão para o horizonte h0 (figura 4) para cada estação do ano relacionando as categorias do observado ocorrido (choveu ou não choveu) com as categorias de previsão (previu chuva ou não). Essa abordagem permite avaliar a capacidade dos modelos em prever corretamente os dias com chuva e os dias sem chuva.

Figura 4 – matriz de confusão – erros e acertos do modelo para a ocorrência ou não de chuva relativo ao total de observações para o período



Na análise geral de desempenho do modelo (figura 4), observou-se que, para a série total analisada (2.193 dias), 63,5% das previsões corresponderam corretamente à não ocorrência de chuva (precipitação diária < 1 mm), enquanto 22,2% representaram acertos na previsão de ocorrência de chuva. Os erros positivos (quando o modelo previu chuva e não choveu) representaram 7,2% dos casos, sendo próximo aos erros negativos (previsão de tempo seco quando houve chuva), que ocorreram em 7,1% dos dias. As estações do outono (MAM, com 552 dias) e da primavera (SON, com 637 dias) apresentaram percentuais de erro e acerto semelhantes aos da série do período total. Em contrapartida, o verão (DJF, com 597 dias) e o inverno (JJA, com 568 dias) mostraram desempenhos distintos. No inverno, o modelo teve maior precisão na previsão de tempo seco, com 87,9% de acertos e apenas 2,7% de erros positivos, além de 6,3% de acertos em dias chuvosos e 3,1% de erros negativos. No verão, o modelo teve acertos positivos e negativos próximos (41,4% e 36,1%) mas as taxas de erros foram as maiores com relação aos demais períodos com 11,2% para ambos os erros negativos e positivos.

Foram calculadas, também, a acurácia, o recall e a precisão com base nas categorias da matriz de confusão, para cada estação (tabela 2). A acurácia mede a proporção de previsões corretas em relação ao total de previsões, enquanto o recall avalia a eficiência do modelo em identificar corretamente os dias de chuva (casos positivos). Já a precisão mede a proporção de acertos de chuva entre todas as vezes que o modelo previu chuva (ou seja, previu um evento positivo). De modo geral, os resultados indicam desempenho satisfatório do modelo, com acurácia variando entre 74,59% (verão) e 94,2% (inverno), refletindo uma boa capacidade de acerto ao longo das estações. O verão apresentou a menor acurácia, mas, em contrapartida, teve o maior recall (90,81%), o que indica que, embora o modelo tenha cometido mais erros no total, foi muito eficaz em identificar os dias com chuva. Já no inverno, apesar da alta acurácia (94,2%), o recall foi o menor entre as estações (67,31%), sugerindo que o modelo teve dificuldade em identificar todos os dias chuvosos, mesmo acertando a maioria das previsões gerais. A precisão oscilou menos entre as estações, ficando entre 63,03% (outono) e 70% (inverno), indicando que, em todas as estações, quando o modelo previu chuva, cerca de dois terços dessas previsões estavam corretas. Esses resultados mostram uma relação típica entre recall e precisão, principalmente no verão, onde o modelo priorizou identificar ao máximo os dias chuvosos (alto recall), ainda que com maior número de

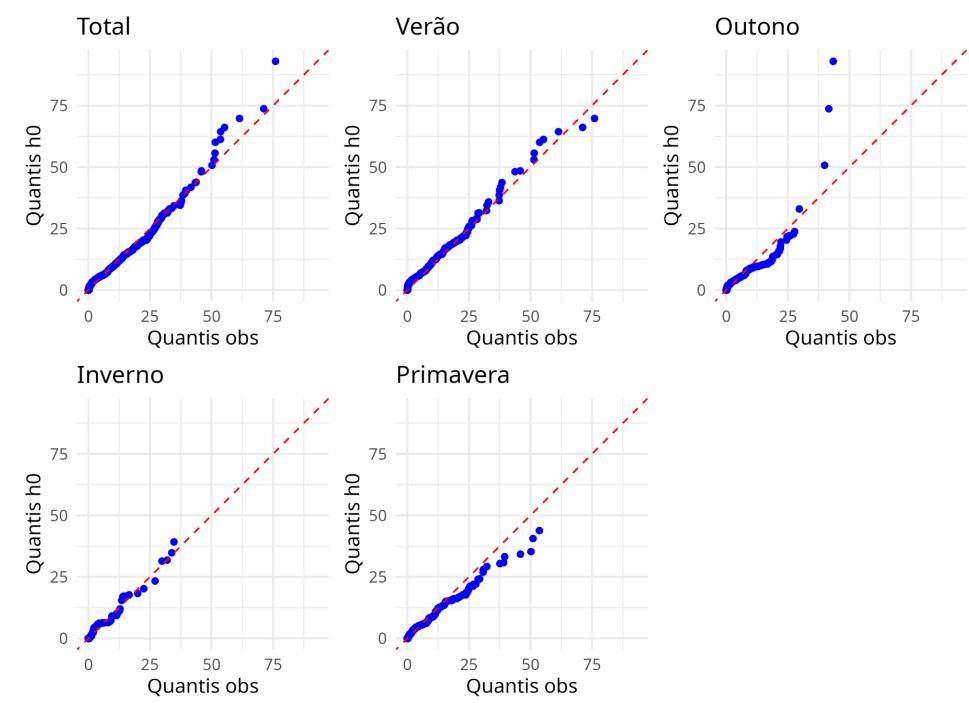
falsos positivos (precisão moderada). Já no inverno, houve maior cautela nas previsões, com menos falsos positivos, o que levou a menor recall, mas maior precisão e acurácia.

Tabela 2 – Métricas de acerto e erro (acurácia, precisão, recall) – desempenho de h0 em classificar corretamente os eventos.

	Total	Verão	Outono	Inverno	Primavera
Acurácia	83,26	74,59	83,88	94,2	80,22
Precisão	67,4	69,65	63,03	70	66,15
Recall	82,1	90,81	78,79	67,31	74,71

Segundo Muller et al. (2016) a performance do modelo é melhor em climas úmidos em comparação com climas áridos a semiáridos, que possuem maior número de falso alarmes e menor precisão. Para a região do Paraná os autores apresentaram uma acurácia entre 0,6 e 0,7, precisão entre 0,8 e 0,9 utilizando a média dos horizontes. Para um estudo de caso de seca (Muller et al. 2016) o WRF representou bem a seca, mas com uma tendência a superestimar a severidade da seca em termos quantitativos, o que sugere a correção ou ajuste com métodos de correção de viés. Erros sistemáticos também foram encontrados por Gomes et al. (2022).

Figura 5 – Diagrama quantil x quantil de cada período analisado.



Quanto ao diagrama de quantil (figura 5) para a série total, o modelo apresenta boa aderência nos quantis centrais, mas superestima os quantis mais altos, prevendo valores maiores do que os observados. No verão, o padrão é semelhante, com aderência geral razoável, mas com ligeira subestimação nos extremos superiores, isso é esperado, pois o verão é uma estação com maior frequência de chuvas intensas, o que pode ser mais difícil de modelar. Já no outono, o modelo mostra superestimação significativa nos quantis mais altos, o que sugere que ele não está capturando adequadamente os eventos mais intensos dessa estação. O inverno apresenta o melhor desempenho geral, em que os quantis modelados estão muito próximos dos observados em toda a

distribuição, com pequena oscilação, indicando uma boa aderência, isso pode ocorrer porque o inverno apresenta menos variabilidade nas chuvas e menos eventos extremos, facilitando o ajuste do modelo. Na primavera, nota-se uma tendência à subestimação dos quantis altos. Em síntese, o modelo responde melhor no inverno, com ótima fidelidade em todos os quantis, enquanto tende a superestimar eventos extremos no outono e na série total e superestimar os mais intensos no verão e primavera.

Técnicas de correção

Em relação ao dado previsto, sem correção, o método QMAP (Weibull) apresentou as seguintes melhorias percentuais por período: 3,71% (3,95%) no verão, 3,01% (2,58%) no outono, 2,96% (4,31%) na primavera, e 2,85% (2,85%) no período total (tabela 3). No inverno, os valores permaneceram iguais, sem melhoria no percentual. Esses resultados reforçam a efetividade do QMAP e Weibull especialmente nos períodos de maior variabilidade hidrológica.

Tabela 3 - Porcentagem de acerto positivo e negativo (somados) após correção dos dados por cada método

	Previsto	LOC	Offset	Qmap log	Weibull	Gamma top
Inverno	94,2	94,2	94,2	94,2	94,2	87,86
Outono	83,88	83,88	83,88	86,41	86,05	85,87
Primavera	80,41	80,4	80,41	82,79	83,88	82,6
Total	83,36	83,68	83,68	85,73	85,73	85,37
Verão	74,77	77,16	77,53	77,54	77,72	75,69

Após a aplicação dos métodos de correção (Weibull e QMAP), observou-se uma melhora geral no desempenho do modelo em relação aos dados originais, conforme avaliado pelas métricas de taxa de acerto, recall e precisão para cada estação do ano (tabela 4). No total do período analisado, a taxa de acerto aumentou em 3,0% com Weibull e 3,3% com QMAP. A precisão subiu com Weibull em 10,6% e com QMAP em 12,6%, o que demonstra um ganho expressivo na capacidade do modelo de prever corretamente os dias chuvosos quando há uma previsão de chuva. Por outro lado, o recall diminuiu em -5,9% para Weibull e -7,5% para QMAP, indicando uma leve perda na sensibilidade do modelo para identificar todos os eventos ocorridos de chuva. No verão, houve uma elevação na taxa de acerto de 3,9% com Weibull e 3,4% com QMAP. A precisão aumentou em 8,5% com Weibull e 11,8% com QMAP. Já o recall, que era inicialmente alto, reduziu-se em -7,4% com Weibull e em -13,6% com QMAP. No outono, a taxa de acerto aumentou com Weibull em 2,6% e com QMAP em 3,0%. A precisão subiu 11,2% com Weibull e 13,3% com QMAP. O recall teve uma pequena queda de -7,7% com Weibull e 71,97% com QMAP (-8,6%). Durante o inverno, a taxa de acerto já era alta no modelo original e se manteve estável após as correções. O recall com Weibull foi ligeiramente inferior ao original (-2,9%), enquanto a precisão melhorou levemente (+1,2%) com Weibull e permaneceu em 70% com QMAP. Na primavera, houve melhora na taxa de acerto com Weibull (4,8%) e com QMAP (3,4%). A precisão aumentou em +15,0% com Weibull e para 9,6% com QMAP. O recall teve pequena redução, -4,7% e -2,4% para Weibull e QMAP, respectivamente. No geral, dois métodos de correção apresentaram ganhos consistentes em taxa de acerto e, principalmente, em precisão, indicando uma maior confiabilidade nas previsões de chuva. O QMAP destacou-se pela maior precisão, enquanto o Weibull manteve valores de recall geralmente mais altos, ou seja, melhor capacidade de detectar a ocorrência de chuva. No entanto, ambos apresentaram pequenas perdas de sensibilidade (recall), o que é um “trade-off” comum quando se busca reduzir falsos positivos.

Tabela 4 - Métricas de acerto e erro (acurácia, precisão, recall) – desempenho dos modelos corrigidos em classificar corretamente os eventos.

		Total	Verão	Outono	Inverno	Primavera
Weibull	acurácia	85,73	77,53	86,05	94,20	84,07
	recall	77,24	84,10	72,73	65,38	71,18
	precisão	74,55	75,56	70,07	70,83	76,10
Qmap	acurácia	86,00	77,16	86,41	94,20	82,97
	recall	75,98	78,45	71,97	67,31	72,94
	precisão	75,86	77,89	71,43	70,00	72,51

As métricas de desempenho dos modelos de correção foram avaliadas considerando o período total e as estações do ano. Para o período total, observou-se uma melhora no viés para a maioria dos modelos, com destaque para o método QMAP, cujo viés foi reduzido de 0,106 para 0,020. A exceção foi o modelo baseado na distribuição Weibull, que não apresentou melhora nesse critério. No entanto, as demais métricas (RMSE, correlação e KGE) permaneceram praticamente inalteradas para todos os modelos. No verão, todos os métodos reduziram o viés, sendo a maior melhora observada no modelo Weibull, que passou de 0,899 para -0,021. Apesar disso, as demais métricas (RMSE, correlação e KGE) mantiveram-se estáveis, sem variações significativas. No outono, o viés inicial já era relativamente baixo, e, nesse contexto, todos os métodos apresentaram uma leve piora, exceto o QMAP, que mostrou uma pequena melhora ao passar de -0,069 para 0,045. As demais métricas pouco se alteraram. Durante o inverno, o desempenho geral dos modelos já era satisfatório, com viés reduzido. Ainda assim, o QMAP conseguiu promover uma leve melhora adicional, reduzindo o viés de -0,018 para -0,009. As métricas RMSE, correlação e KGE mantiveram-se praticamente constantes, enquanto o desempenho do modelo Gama apresentou uma leve piora. Por fim, na primavera, todos os métodos apresentaram melhora no viés, com destaque mais uma vez para o QMAP, que reduziu o valor de -0,381 para 0,058. As demais métricas, como nas demais estações, permaneceram praticamente inalteradas.

CONCLUSÃO

A correção de viés dos dados de precipitação são importantes para a qualidade dos resultados das análises e modelos em que ela serve de entrada. Foram analisadas correções dos dados do modelo WRF através de cinco métodos (offset, LOC, QMAP log, Weibull e Gamma) aplicados sob o horizonte do próprio dia (h_0). Os dados foram corrigidos por estação do ano e a estação com mais (menos) erros é o verão (inverno) com 74,77% (94,2%), conforme a matriz de confusão. O modelo com melhor desempenho foi o QMAP e o Weibull para o verão, aumentando o acerto em 3,7% e 3,9%, respectivamente, mas que também melhoraram o acerto dos demais períodos. Os melhores valores de bias foram observados com o método QMAP, que se destacou na maioria dos períodos, reduzindo o viés de forma consistente, especialmente na primavera (de -0,381 para 0,058) e no período total (de 0,106 para 0,020). O método Weibull teve bom desempenho no verão, mas não mostrou melhora no período total. As demais métricas (RMSE, correlação e KGE) permaneceram estáveis para quase todos os modelos, indicando que os ganhos de desempenho concentraram-se na redução do viés. De modo geral, os resultados obtidos mostram que o modelo apresentou boa capacidade de identificar corretamente os dias com e sem chuva, com destaque para a estação do inverno, que obteve a maior taxa de acerto (94,2%) no cenário original. Após a

aplicação dos métodos de correção, observou-se uma melhora consistente na acurácia (ou taxa de acerto) e na precisão, especialmente com o método QMAP, que elevou a precisão total em 12,6%. O método Weibull também teve impacto positivo, com aumento da precisão em 10,6% e da taxa de acerto em 3,0%. Em contrapartida, o recall apresentou leve queda, indicando que parte da sensibilidade na detecção de dias chuvosos foi sacrificada em prol da redução de falsos positivos. Ainda assim, ambos os métodos contribuíram para melhorar a confiabilidade das previsões de chuva, com destaque para os ganhos durante a primavera e o verão.

REFERÊNCIAS

- BUGHICI, T.; LAZAROVITCH, N.; FREDJ, E.; TAS, E. (2019). “Evaluation and Bias Correction in WRF Model Forecasting of Precipitation and Potential Evapotranspiration”. *Journal of Hydrometeorology*, 20(5), pp. 965–983. <https://doi.org/10.1175/JHM-D-18-0160.1>
- GOMES, H. B.; SILVA, M. C. L.; BARBOSA, H. M. J.; AMBRIZZI, T.; BALTAZI, H.; GOMES, H. B.; SILVA, F. D. S.; COSTA, R. L.; FIGUEROA, S. N.; HERDIES, D. L.; et al. (2022). “WRF Sensitivity for Seasonal Climate Simulations of Precipitation Fields on the CORDEX South America Domain”. *Atmosphere*, 13(1), pp. 107. <https://doi.org/10.3390/atmos13010107>
- MÜLLER, O. V.; LOVINO, M. A.; BERBERY, E. H. (2016). “Evaluation of WRF Model Forecasts and Their Use for Hydroclimate Monitoring over Southern South America”. *Weather and Forecasting*, 31(3), pp. 1001–1017. <https://doi.org/10.1175/WAF-D-15-0130.1>
- SKAMAROCK, W.; KLEMP, J.; DUDHIA, J.; GILL, D. O.; LIU, Z.; BERNER, J.; WANG, W.; POWERS, J. G.; DUDA, M. G.; BARKER, D.; HUANG, X.-Y. (2019). “A Description of the Advanced Research WRF Model Version 4.1”. *NCAR Technical Note*, NCAR/TN-556+STR, 145 pp, 145. <https://doi.org/10.5065/1dfh-6p97>
- CONGALTON, R. G.; GREEN, K. (2009). “Assessing the Accuracy of Remotely Sensed Data: Principles and Practices”. 2nd ed. CRC Press, Taylor & Francis Group, 183 pp. ISBN: 978-1-4200-5512-2.
<https://www.crcpress.com/Assessing-the-Accuracy-of-Remotely-Sensed-Data-Principles-and-Practices/Congalton-Green/p/book/9781420055122>

AGRADECIMENTOS

Os autores gostariam de agradecer ao Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR) pelo apoio e agradecem os Comitês PCJ e a Agência das Bacias PCJ pela oportunidade de realização deste estudo.