



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL
DOUTORADO EM RECURSOS HÍDRICOS

EVERTON SANTOS CASTRO

PREVISÕES SUB-SAZONAIS DE CHUVA VAZÃO PARA BACIAS HIDROGRÁFICAS
DO NORDESTE BRASILEIRO

FORTALEZA

2023

EVERTON SANTOS CASTRO

PREVISÕES SUB-SAZONAIS DE CHUVA VAZÃO PARA BACIAS HIDROGRÁFICAS DO
NORDESTE BRASILEIRO

Tese apresentada ao Programa de Pós-Graduação em Engenharia civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Civil. Área de Concentração: Recursos Hídricos

Orientador: Prof. Dr. Cleiton da Silva
Silveira

Coorientador: Dr. Francisco das Chagas
Vasconcelos Júnior

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

C35p Castro, Everton Santos.
Previsões Sub-Sazonais de chuva vazão para bacias hidrográficas do nordeste brasileiro / Everton Santos Castro. – 2023.
212 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Recursos Hídricos, Fortaleza, 2023.
Orientação: Prof. Dr. Cleiton da Silva Silveira.
Coorientação: Prof. Dr. Francisco das Chagas Vasconcelos Júnior.

1. Modelagem Hidrológica sub-sazona. 2. Redes Neurais Híbridas. 3. Semiárido Brasileiro.. I. Título.
CDD 627

EVERTON SANTOS CASTRO

PREVISÕES SUB-SAZONAIS DE CHUVA VAZÃO PARA BACIAS HIDROGRÁFICAS DO
NORDESTE BRASILEIRO

Tese apresentada ao Programa de Pós-Graduação em Engenharia civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Civil. Área de Concentração: Recursos Hídricos

Aprovada em: 28 de Agosto de 2023

BANCA EXAMINADORA

Prof. Dr. Cleiton da Silva Silveira (Orientador)
Universidade Federal do Ceará (UFC)

Dr. Francisco das Chagas Vasconcelos Júnior (Coorientador)
Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME)

Prof. Dr. Iran Eduardo Lima Neto
Universidade Federal do Ceará (UFC)

Prof. Dra. Samiria Maria Oliveira da Silva
Universidade Federal do Ceará (UFC)

Dr. Samuellson Lopes Cabral
Centro Nacional de Monitoramento e Alertas de Desastres Naturais
(CEMADEN)

Dra. Meiry Sayuri Sakamoto
Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME)

AGRADECIMENTOS

A Deus, o que seria de mim sem a fé que tenho n'Ele.

Dedico também esta, bem como todas as demais conquistas, à minha esposa, Ana Gabriela, que sempre me incentivou com seu amor, carinho, atenção e compreensão. Aos meus pais Martinho Castro e Solange Castro, minhas irmãs Daiane Castro e Liliane Castro, cujo apoio e amor incondicional foram fundamentais para alcançar esta etapa em minha jornada.

Expresso também minha profunda gratidão a todos os professores do departamento de Engenharia Hidráulica e Ambiental da Universidade Federal do Ceará, que me proporcionaram não apenas conhecimento racional, mas também a manifestação do caráter e da afetividade da educação durante o meu processo de formação profissional. Agradeço em especial, aos professores Dr. José Nílson (em memória) e Dr. Cleiton Silveira, por suas valiosas orientações, incentivo e por acreditar no meu potencial. Sem vocês jamais teria conseguido superar as dificuldades que enfrentei. Agradeço também ao Dr. Júnior Vasconcelos por suas valiosas contribuições e pela paciência demonstrada ao assumir o papel de coorientador neste trabalho.

Aos meus grandes amigos, Adriano Oliveira, Dimitry Pessoa, Leandro Filho, pela verdadeira amizade e pelo companheirismo, desde os tempos de graduação. Aos amigos Eduardo Lima, Paulo Pimenta e Duarte Júnior pelas valiosas conversas e sugestões que contribuíram significativamente no desenvolvimento desta pesquisa.

Por fim, à Fundação Cearense de Apoio ao Desenvolvimento (Funcap) pelo apoio financeiro com a manutenção da bolsa de auxílio.

“O sonho é que leva a gente para frente. Se a gente for seguir a razão, fica aquietado, acomodado.”

(Ariano Suassuna)

RESUMO

O Brasil, sendo um país de vasta extensão, enfrenta desafios relacionados à escassez de chuvas em várias regiões. No entanto, é na região Nordeste do Brasil (NEB) que essa condição se manifesta com maior frequência. A Bacia Hidrográfica do rio São Francisco, localizada em sua maior porção no NEB, e as bacias do Nordeste Setentrional brasileiro, historicamente convive com problemas relacionados à escassez de água. Os impactos da variabilidade climática são sentidos em setores como a agricultura, na agroindústria, na agropecuária, na geração de energia, na irrigação, na saúde humana e na geração de emprego. Nesse contexto, o monitoramento e previsão de variáveis hidrológicas é de extrema importância para orientar a implementação de estratégias de mitigação e adaptação. Para tanto, estudos foram desenvolvidos visando analisar a variabilidade sub-sazonal de precipitações na região; analisar o desempenho de modelos de previsão sub-sazonal de precipitação; calibração do modelo hidrológico SMAP e desenvolver modelos híbridos de RNAs baseados em *wavelets* para previsão de vazões. A análise da variabilidade das precipitações revelaram a existência de flutuações de curta duração e alta frequência dentro de uma estação chuvosa, evidenciando uma variabilidade sub-sazonal consistente em todas as regiões estudadas. A Oscilação Madden-Julian associada ao El Niño Oscilação Sul demonstrou ter uma influência significativa na variabilidade dessas precipitações. Entre os modelos de previsão de precipitação analisados os resultados indicam que os modelos CFSv2 e GEFSv2 apresentaram desempenho superior. Constatou-se também que os modelos do CPTEC e ESRL apresentaram limitações de desempenho, principalmente nas simulações das bacias do Ceará. Por fim, os estudos relacionados a implementação de redes neurais híbridas, demonstraram resultados animadores. Nas bacias de Três Marias e Sobradinho, a rede neural híbrida alcançou um coeficiente de eficiência de *Nash* próximo a 0,9 para previsões de curto prazo. Nas bacias o Xingó, Luiz Gonzaga e Paulo Afonso, o modelo conseguiu capturar a tendência das séries de vazão e houve melhorias significativas em comparação com a RNA tradicionais. No entanto, nas bacias do Ceará, a falta de dados de qualidade prejudicou consideravelmente o desempenho do modelo. Nos estudos comparativos, as previsões realizadas pela WRNA superaram o desempenho do SMAP e apresentou, de forma geral, melhores índices estatísticos que os modelos utilizados pelo ONS.

Palavras-chave: Modelagem Hidrológica sub-sazonal. Redes Neurais Híbridas. Semiárido Brasileiro.

ABSTRACT

Brazil, being a country of vast extension, faces challenges related to the scarcity of rainfall in several regions. However, it is in the Northeast region of Brazil (NEB) that this condition manifests most frequently. The Hydrographic Basin of the São Francisco River, located mostly in the NEB, and the basins of the Northern Northeast of Brazil, have historically dealt with water scarcity issues. The impacts of climate variability are felt in sectors such as agriculture, agribusiness, livestock farming, energy generation, irrigation, human health, and job creation. In this context, monitoring and forecasting hydrological variables are of utmost importance to guide the implementation of mitigation and adaptation strategies. To that end, studies were conducted to analyze sub-seasonal precipitation variability in the region; assess the performance of sub-seasonal precipitation forecast models; calibrate the SMAP hydrological model; and develop hybrid neural network models based on wavelets for streamflow prediction. The analysis of precipitation variability revealed the existence of short-duration, high-frequency fluctuations within a rainy season, highlighting a consistent sub-seasonal variability across all studied regions. The Madden-Julian Oscillation associated with the El Niño Southern Oscillation demonstrated a significant influence on the variability of these precipitations. Among the analyzed precipitation forecast models, the results indicate that the CFSv2 and GEFSv2 models exhibited superior performance. It was also noted that the CPTEC and ESRL models showed performance limitations, especially in simulations of the Ceará basins. Finally, studies related to the implementation of hybrid neural networks have demonstrated promising results. In the Três Marias and Sobradinho basins, the hybrid neural network achieved a Nash efficiency coefficient close to 0.9 for short-term forecasts. In the Xingó, Luiz Gonzaga, and Paulo Afonso basins, the model managed to capture the trend of flow series and showed significant improvements compared to traditional neural networks. However, in the Ceará basins, the lack of quality data considerably hindered the model's performance. In comparative studies, the forecasts made by the hybrid neural network outperformed the performance of SMAP and, in general, exhibited better statistical indices than the models used by ONS.

Keywords: Sub-seasonal Hydrological Forecasts. Hybrid Neural Networks. Brazilian Semiarid.

LISTA DE FIGURAS

Figura 1 – Área de estudo	23
Figura 2 – Bacias e reservatórios estudados	25
Figura 3 – Célula de Walker durante ENOS neutro	27
Figura 4 – Célula de Walker durante eventos de El Niño e La Niña	28
Figura 5 – Anomalias do potencial de velocidade do vento a 850 hPa e de precipitações	29
Figura 6 – Diagrama das fases da Oscilação Madden-Julian (OMJ)	30
Figura 7 – Árvore de decomposição de <i>wavelets</i>	34
Figura 8 – Ocorrência de El Niño e de La Niña.	39
Figura 9 – Climatologia da Precipitação mensal.	41
Figura 10 – Precipitações mensais na estação chuvosa.	42
Figura 11 – (a) Hietograma da bacia do Banabuiú. (b) Espectro de potência <i>wavelet</i> . (c) Espectro de potência global (d) Potência de onda média na escala de faixa de 30-90 dias.	44
Figura 12 – Mesmo que a Figura 11, mas para bacia do Orós	45
Figura 13 – Mesmo que a Figura 11, mas para bacia do Castanhão	45
Figura 14 – Mesmo que a Figura 11, mas para bacia do Xingó.	46
Figura 15 – Mesmo que a Figura 11, mas para bacia de Paulo Afonso	46
Figura 16 – Mesmo que a Figura 11, mas para bacia de Luiz Gonzaga	47
Figura 17 – Mesmo que a Figura 11, mas para bacia de Sobradinho	47
Figura 18 – Mesmo que a Figura 11, mas para bacia de Três Marias	48
Figura 19 – Mesmo que a Figura 11, mas para bacia de Retiro Baixo	48
Figura 20 – Anomalias da precipitação média (mm dia^{-1}) para as diferentes fases da OMJ (Fase ativa).	50
Figura 21 – Mesmo que a Figura 20, mas para fase inativa	51
Figura 22 – Proporção de chuvas extremas: OMJ coincidindo com ENOS neutro.	53
Figura 23 – Proporção de chuvas extremas: OMJ coincidindo com El Niño.	54
Figura 24 – Proporção de chuvas extremas: OMJ coincidindo com La Niña.	55
Figura 25 – Viés das previsões de precipitação realizadas pelos modelos.	66
Figura 26 – MSE das previsões de precipitação realizadas pelos modelos.	67
Figura 27 – RMSE das previsões de precipitação realizadas pelos modelos.	68
Figura 28 – <i>NSE</i> das previsões de precipitação realizadas pelos modelos.	69

Figura 29 – Coeficiente de correlação de Pearson (r) das previsões de precipitação realizadas pelos modelos.	71
Figura 30 – Estrutura do modelo SMAP na versão diária.	75
Figura 31 – Bacia do Retiro Baixo - Validação SMAP.	83
Figura 32 – Bacia de Três Marias - Validação SMAP.	83
Figura 33 – Bacia de Sobradinho - Validação SMAP.	84
Figura 34 – Bacia de Luiz Gonzaga - Validação SMAP.	84
Figura 35 – Bacia de Paulo Afonso - Validação SMAP.	84
Figura 36 – Bacia de Xingó - Validação SMAP.	85
Figura 37 – Bacia do Castanhão - Validação SMAP.	85
Figura 38 – Bacia do Orós - Validação SMAP.	85
Figura 39 – Bacia do Banabuiú - Validação SMAP.	86
Figura 40 – Modelo de Neurônio Biológico	90
Figura 41 – Neurônio Artificial	91
Figura 42 – Exemplo de rede feedforward de camada única	93
Figura 43 – Exemplo de rede feedforward de camadas múltiplas	94
Figura 44 – Exemplo de rede neural recorrente	95
Figura 45 – Exemplo de <i>Long Short-Term Memory</i>	95
Figura 46 – Notação da RNA Perceptron multicamadas	97
Figura 47 – Decomposição da série de precipitação - <i>wavelets (coif5)</i>	103
Figura 48 – Decomposição da série de vazão - <i>wavelets (coif5)</i>	103
Figura 49 – Previsão WRNA - Retiro Baixo 7 e 14 dias	127
Figura 50 – Previsão WRNA - Retiro Baixo 21 e 28 dias	128
Figura 51 – Previsão WRNA - Três Marias 7 e 14 dias	129
Figura 52 – Previsão WRNA - Três Marias 21 e 28 dias	130
Figura 53 – Previsão WRNA - Sobradinho 7 e 14 dias	131
Figura 54 – Previsão WRNA - Sobradinho 21 e 28 dias	132
Figura 55 – Previsão WRNA - Luiz Gonzaga 7 e 14 dias	133
Figura 56 – Previsão WRNA - Luiz Gonzaga 21 e 28 dias	134
Figura 57 – Previsão WRNA - Paulo Afonso 7 e 14 dias	135
Figura 58 – Previsão WRNA - Paulo Afonso 21 e 28 dias	136
Figura 59 – Previsão WRNA - Xingó 7 e 14 dias	137

Figura 60 – Previsão WRNA - Xingó 21 e 28 dias	138
Figura 61 – Previsão WRNA - Castanhão 7 e 14 dias	139
Figura 62 – Previsão WRNA - Castanhão 21 e 28 dias	140
Figura 63 – Previsão WRNA - Orós 7 e 14 dias	141
Figura 64 – Previsão WRNA - Orós 21 e 28 dias	142
Figura 65 – Previsão WRNA - Banabuiú 7 e 14 dias	143
Figura 66 – Previsão WRNA - Banabuiú 21 e 28 dias	144
Figura 67 – Bacia de Três Marias	151
Figura 68 – Bacia de Sobradinho	151
Figura 69 – Bacia do Xingó	151
Figura 70 – Bacia do Castanhão	152
Figura 71 – Avaliação de desempenho: vazões médias semanais (2015)	153
Figura 72 – Avaliação de desempenho: vazões médias semanais (2015)	153
Figura 73 – Avaliação de desempenho: vazões médias semanais (2014)	154
Figura 74 – Avaliação de desempenho: vazões médias semanais (2014)	155
Figura 75 – Bacia do Retiro Baixo - Calibração SMAP.	170
Figura 76 – Bacia de Três Marias - Calibração SMAP.	170
Figura 77 – Bacia de Sobradinho - Calibração SMAP.	170
Figura 78 – Bacia de Luiz Gonzaga - Calibração SMAP.	171
Figura 79 – Bacia de Paulo Afonso - Calibração SMAP.	171
Figura 80 – Bacia de Xingó - Calibração SMAP.	171
Figura 81 – Bacia do Castanhão - Calibração SMAP.	172
Figura 82 – Bacia do Orós - Calibração SMAP.	172
Figura 83 – Bacia do Banabuiú - Calibração SMAP.	172
Figura 84 – Previsão RNA - Retiro Baixo 7 e 14 dias	173
Figura 85 – Previsão RNA - Retiro Baixo 21 e 28 dias	174
Figura 86 – Previsão RNA - Retiro Baixo 35 e 42 dias	175
Figura 87 – Previsão RNA - Três Marias 7 e 14 dias	176
Figura 88 – Previsão RNA - Três Marias 21 e 28 dias	177
Figura 89 – Previsão RNA - Três Marias 35 e 42 dias	178
Figura 90 – Previsão RNA - Sobradinho 7 e 14 dias	179
Figura 91 – Previsão RNA - Sobradinho 21 e 28 dias	180

Figura 92 – Previsão RNA - Sobradinho 35 e 42 dias	181
Figura 93 – Previsão RNA - Luiz Gonzaga 7 e 14 dias	182
Figura 94 – Previsão RNA - Luiz Gonzaga 21 e 28 dias	183
Figura 95 – Previsão RNA - Luiz Gonzaga 35 e 42 dias	184
Figura 96 – Previsão RNA - Paulo Afonso 7 e 14 dias	185
Figura 97 – Previsão RNA - Paulo Afonso 21 e 28 dias	186
Figura 98 – Previsão RNA - Paulo Afonso 35 e 42 dias	187
Figura 99 – Previsão RNA - Xingó 7 e 14 dias	188
Figura 100–Previsão RNA - Xingó 21 e 28 dias	189
Figura 101–Previsão RNA - Xingó 35 e 42 dias	190
Figura 102–Previsão RNA - Castanhão 7 e 14 dias	191
Figura 103–Previsão RNA - Castanhão 21 e 28 dias	192
Figura 104–Previsão RNA - Castanhão 35 e 42 dias	193
Figura 105–Previsão RNA - Orós 7 e 14 dias	194
Figura 106–Previsão RNA - Orós 21 e 28 dias	195
Figura 107–Previsão RNA - Orós 35 e 42 dias	196
Figura 108–Previsão RNA - Banabuiú 7 e 14 dias	197
Figura 109–Previsão RNA - Banabuiú 21 e 28 dias	198
Figura 110–Previsão RNA - Banabuiú 35 e 42 dias	199
Figura 111–Previsão WRNA - Retiro Baixo 35 e 42 dias	202
Figura 112–Previsão WRNA - Retiro Baixo 35 e 42 dias	203
Figura 113–Previsão WRNA - Sobradinho 35 e 42 dias	204
Figura 114–Previsão WRNA - Luiz Gonzaga 35 e 42 dias	205
Figura 115–Previsão WRNA - Paulo Afonso 35 e 42 dias	206
Figura 116–Previsão WRNA - Xingó 35 e 42 dias	207
Figura 117–Previsão WRNA - Castanhão 35 e 42 dias	208
Figura 118–Previsão WRNA - Orós 35 e 42 dias	209
Figura 119–Previsão WRNA - Banabuiú 35 e 42 dias	210

LISTA DE TABELAS

Tabela 1 – Limite de Variação dos Parâmetros do modelo SMAP Diário.	78
Tabela 2 – Períodos analisados	81
Tabela 3 – Indicadores de desempenho - SMAP	82
Tabela 4 – Parâmetros do modelo SMAP após calibração	86
Tabela 5 – Configurações da RNA e WRNA	104
Tabela 6 – Períodos analisados	104
Tabela 7 – Previsões (RNA) - Retiro Baixo	109
Tabela 8 – Previsões (RNA) - Três Marias	110
Tabela 9 – Previsões (RNA) - Sobradinho	111
Tabela 10 – Previsões (RNA) - Luis Gonzaga	112
Tabela 11 – Previsões (RNA) - Paulo Afonso	113
Tabela 12 – Previsões (RNA) - Xingó	114
Tabela 13 – Previsões (RNA) - Castanhão	115
Tabela 14 – Previsões (WRNA) - Retiro Baixo	120
Tabela 15 – Previsões (WRNA) - Três Marias	121
Tabela 16 – Previsões (WRNA) - Sobradinho	122
Tabela 17 – Previsões (WRNA) - Luis Gonzaga	123
Tabela 18 – Previsões (WRNA) - Paulo Afonso	124
Tabela 19 – Previsões (WRNA) - Xingó	125
Tabela 20 – Previsões (WRNA) - Castanhão	126
Tabela 21 – Indicadores de desempenho	150
Tabela 22 – Previsões (RNA) - Orós	200
Tabela 23 – Previsões (RNA) - Banabuiú	201
Tabela 24 – Previsões (WRNA) - Orós	211
Tabela 25 – Previsões (WRNA) - Banabuiú	212

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas
ANEEL	Agência Nacional de Energia Elétrica
AnnAGNPS	<i>Annualized Agricultural NonPoint Source model</i>
BAM	<i>Brazilian Global Atmospheric Model</i>
BHSF	Bacia Hidrográfica do rio São Francisco
CFSv2	<i>Climate Forecast System Version 2</i>
COGERH	Companhia de Gestão dos Recursos Hídricos
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
ENOS	El Niño Oscilação Sul
ESRL	<i>Earth System Research Laboratory</i>
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
GEFSv2	<i>Global Ensemble Forecast System Version 2</i>
GWS	Espectro global da <i>wavelet</i>
IOS	Índice de Oscilação Sul
MCG	Modelos Numéricos de Circulação Geral
NCEP	National Centers for Environmental Prediction
NEB	Nordeste Brasileiro
NOAA	<i>National Oceanic and Atmospheric Administration</i>
OMJ	Oscilação Madden-Julian
ONS	Operador Nacional do Sistema Elétrico
PMC	Perceptron multicamadas
PMO	Programa Mensal de Operação
PSO	<i>Particle Swarm Optimization</i>
RNAs	Redes Neurais Artificiais
SIN	Sistema Interligado Nacional
SMAP	<i>Soil Moisture Accounting Procedure</i>
SWAT	<i>Soil and Water Assessment Tool</i>
TSM	Temperatura da Superfície do Mar
TWD	Transformada de <i>Wavelets</i> Discreta
ZCIT	Zona de Convergência Intertropical

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Justificativa	18
1.2	Objetivos	20
1.3	Relevância e Originalidade	20
1.4	Estrutura do Trabalho	21
2	VARIABILIDADE TEMPORAL E ESPACIAL DAS CHUVAS	22
2.1	Introdução	22
2.2	Área de Estudo	22
2.3	Modos de variabilidade	26
2.4	Transformada <i>Wavelets</i>	31
2.4.1	<i>Transformada waveltes discreta (TWD)</i>	32
2.4.2	<i>Wavelets como filtro de passagem</i>	33
2.4.3	<i>Famílias Wavelets</i>	35
2.5	Metodologia	37
2.6	Resultados e discussões	40
2.6.1	<i>Análises de Wavelet</i>	43
2.6.2	<i>Análise da influência dos Modos de Variabilidade</i>	49
2.7	Conclusões	55
3	AVALIAÇÃO DA PERFORMANCE DE MODELOS NUMÉRICOS PARA PREVISÃO SUB-SAZONAL DE PRECIPITAÇÃO	57
3.1	Introdução	57
3.2	Modelos matemáticos	59
3.3	Metodologia	61
3.3.1	<i>Modelos Analisados</i>	62
3.3.2	<i>Validação das previsões</i>	63
3.4	Resultados	65
3.5	Conclusões	71
4	MODELAGEM HIDROLÓGICA VIA SMAP	73
4.1	Introdução	73
4.2	O modelo SMAP	74

4.3	Metodologia	78
4.4	Resultados	82
4.5	Conclusões	87
5	REDES NEURAIIS	88
5.1	Introdução	88
5.1.1	<i>Neurônios Biológicos</i>	90
5.1.2	<i>Neurônios Artificiais</i>	91
5.1.3	<i>Arquiteturas de RNAs</i>	92
5.1.4	<i>Treinamentos de RNAs</i>	96
5.1.5	<i>Algoritmo de Aprendizagem backpropagation</i>	96
5.1.6	<i>Modelos Híbridos de Redes Neurais</i>	100
5.2	Metodologia	101
5.2.1	<i>Modelos Propostos</i>	101
5.2.2	<i>Avaliação das previsões</i>	105
5.3	Resultados	107
5.3.1	<i>Redes Neurais Tradicionais</i>	107
5.3.2	<i>Redes Neurais - Wavelets</i>	116
5.4	Conclusões	145
6	COMPARATIVO DE DESEMPENHO	147
6.1	Introdução	147
6.2	Metodologia	148
6.3	Resultados	150
6.4	Conclusões	155
7	CONCLUSÕES E RECOMENDAÇÕES	157
	REFERÊNCIAS	160
	ANEXOS	169
	ANEXO A – CALIBRAÇÃO - SMAP	170
	ANEXO B – REDES NEURAIIS TRADICIONAIS	173
	ANEXO C – REDES NEURAIIS -WAVELETS	202

1 INTRODUÇÃO

A compreensão da variabilidade climática em uma determinada região desempenha um papel fundamental no contexto das mudanças climáticas e na busca por políticas públicas eficazes de adaptação e mitigação. É por meio desse entendimento que se torna possível tomar medidas adequadas para reduzir os impactos dessas mudanças e garantir a segurança hídrica e alimentar das comunidades locais (MARENGO *et al.*, 2011; SANTANA; SANTOS, 2020).

Ao conhecer as tendências climáticas e os eventos extremos, como secas prolongadas e enchentes repentinas, torna-se possível tomar decisões informadas e embasadas. Através desse conhecimento, é possível desenvolver estratégias que visem à redução da vulnerabilidade das comunidades e à promoção da resiliência diante dos desafios climáticos.

O Brasil, sendo um país de vasta extensão e diversidade geográfica, enfrenta desafios relacionados à escassez de chuvas em várias regiões. No entanto, é na região Nordeste do Brasil (NEB) que essa condição se manifesta com maior frequência e intensidade, resultando em impactos significativos. Estudos indicam que o NEB é especialmente vulnerável a secas, afetando o abastecimento de água e causando danos socioeconômicos (ALVES *et al.*, 1998; SANTANA; SANTOS, 2020; RODRIGUES, 2016).

Um exemplo marcante dessa realidade foi a última grande seca que assolou a região entre 2012 e 2016. Esse evento climático extremo resultou na destruição de vastas áreas de cultivo e teve um impacto devastador em centenas de cidades e vilarejos do NEB (MARENGO *et al.*, 2017; SANTANA; SANTOS, 2020; MARTINS *et al.*, 2017).

Segundo Marengo *et al.* (2011), é previsto um impacto considerável das mudanças climáticas sobre os recursos hídricos, especialmente na região semiárida do NEB. Nesse contexto, a escassez de água, que já é uma realidade atual, tende a se agravar significativamente. O autor ressalta que a disponibilidade hídrica per capita na região é insuficiente nos Estados do Rio Grande do Norte, Paraíba, Pernambuco, Alagoas e Sergipe, sem mencionar as variações regionais no déficit hídrico, acentuando ainda mais a situação insustentável para os habitantes do semiárido, que enfrentam um estresse hídrico considerável.

O autor ressalta adicionalmente que segmentos cruciais, incluindo agricultura de subsistência, agroindústria, agropecuária, geração de energia, irrigação, saúde pública, migração e geração de emprego, enfrentarão impactos substanciais devido às alterações na disponibilidade e regularidade das chuvas, demandando a adoção de medidas adaptativas e mitigadoras para garantir a segurança hídrica e o desenvolvimento sustentável da região.

Desta forma, a previsão das variáveis hidrológicas assume um papel de destaque na condução eficaz da gestão dos recursos hídricos, especialmente em regiões propensas a sentir os impactos das mudanças climáticas, a exemplo do NEB. Compreender de que maneira as flutuações climáticas influenciam não somente os padrões de precipitação, mas também os fluxos de água nos reservatórios, emerge como um fator essencial para ampliar as perspectivas de assegurar a estabilidade hídrica e fomentar um desenvolvimento sustentável (SILVA *et al.*, 2006).

De acordo com Todini (2007), a modelagem hidrológica teve sua origem há mais de um século, por volta de 1850, com o desenvolvimento de um modelo que tinha como objetivo simular o ciclo hidrológico e regularizar as vazões. Desde então, a modelagem hidrológica tem sido continuamente aprimorada graças ao desenvolvimento computacional e ao progresso das ciências hidrológicas. Atualmente, os modelos hidrológicos são capazes de representar com maior precisão a complexidade dos fenômenos, como a infiltração, a evapotranspiração e a percolação, bem como levar em consideração aspectos topográficos, geológicos e climáticos das bacias hidrográficas.

A gama de modelos existentes na literatura é extensa e sua classificação depende de diferentes aspectos que consideram características específicas. Essas classificações levam em conta fatores, como o tipo de variáveis utilizadas na modelagem (estocásticas ou determinísticas), as relações entre essas variáveis (empíricas ou conceituais), a forma como os dados são representados (discretos ou contínuos), a presença de relações espaciais (concentradas ou distribuídas) e a dependência temporal (estacionários ou dinâmicos)(FILHO *et al.*, 2013).

Entre os diversos tipos de modelos hidrológicos, destaca-se o modelo chuva-vazão, amplamente utilizado na modelagem hidrológica devido à sua capacidade de estimar a transformação da chuva em vazão. Esses modelos são fundamentais para compreender como a precipitação se converte em escoamento ao longo dos canais de drenagem, levando em consideração características específicas da bacia hidrográfica, como topografia, geologia e clima. Os modelos de chuva-vazão enfrentam o desafio de, com base nos princípios do ciclo hidrológico, estimar o volume de escoamento em um determinado momento, principalmente com base nas informações de precipitação (FILHO *et al.*, 2013).

Dentre as diversas técnicas utilizadas na modelagem hidrológica e climatológica, as Redes Neurais Artificiais (RNAs) têm se destacado como uma abordagem promissora, constituindo-se como um mecanismo válido para ser aplicado na predição de variáveis hidrológicas. Desta forma, tal metodologia tem sido amplamente discutida e seus resultados

publicados em diversos estudos (BALLINI *et al.*, 2003; GOMES *et al.*, 2010; SOUSA; SOUSA, 2010; ARAÚJO *et al.*, 2005; RIBEIRO, 2011; FIGUEIREDO *et al.*, 2007; BRAVO *et al.*, 2008). Essas redes, inspiradas no funcionamento do cérebro humano, possuem alta capacidade de aprendizado e generalização a partir de dados de entrada. Composta por neurônios artificiais interconectados, uma rede neural é capaz de processar informações de forma paralela e adaptativa, o que a torna uma ferramenta poderosa na previsão de variáveis hidrológicas e climatológicas (SILVA *et al.*, 2010; FREIRE *et al.*, 2019).

Apesar dos bons resultados alcançados com o uso das RNAs na modelagem hidrológica, pesquisadores têm buscado aprimorar ainda mais a precisão das previsões, recorrendo a modelos híbridos. Essa abordagem envolve a combinação das RNAs com outras técnicas ou metodologias na modelagem hidrológica, visando explorar sinergias e superar possíveis limitações individuais dos métodos utilizados. Essa combinação tem se mostrado promissora e contribui para melhorar a acurácia das previsões e a compreensão dos processos hidrológicos (WANG; DING, 2003; REIS; SILVA, 2004; CANNAS *et al.*, 2006; NOURANI *et al.*, 2009; ADAMOWSKI; CHAN, 2011; ADAMOWSKI *et al.*, 2012; FREIRE *et al.*, 2019).

Mediante ao exposto, o objetivo do presente estudo é investigar a variabilidade das precipitações em uma escala sub-sazonal e desenvolver um modelo de rede neural híbrida para simular a transformação de chuva em vazão nessa mesma escala. As regiões de interesse para esse estudo é a Bacia Hidrográfica do rio São Francisco (BHSF) e sub-bacias localizadas no Estado do Ceará.

1.1 Justificativa

A área de estudo, predominantemente situada no Nordeste Brasileiro (NEB), abrange a BHSF e três sub-bacias localizadas no Estado do Ceará (Bacias do Orós, Castanhão e Banabuiú), que serão beneficiadas pela transposição do rio São Francisco. Ao longo de sua história, a região do NEB tem enfrentado desafios relacionados à escassez de recursos hídricos, especificamente a região conhecida como Semiárido Nordestino (Nordeste Setentrional), se encontra nessa situação. Esta região abrange cerca de 57% da extensão total do NEB, representando um significativo espaço territorial, no qual aproximadamente 40% da população do NEB reside (CBHSF, 2016).

O NEB apresenta fortes padrões de variabilidade climática em variadas escalas de tempo. Os sinais de variabilidades sub-sazonais estão presentes nesta região e diversos estudos apontam a influência de fenômenos em escalas sub-sazonais como possíveis influenciadores de

atividades convectivas (OLIVEIRA *et al.*, 2017; VALADÃO *et al.*, 2017; KAYANO; KOUSKY, 1999; SILVEIRA, 2014).

A gestão dos recursos hídricos na região, engloba um conjunto de etapas interconectadas e estratégias voltadas para otimizar o uso da água, prevenir conflitos e preservar o ecossistema fluvial. Essa gestão fundamenta-se na coleta, análise e monitoramento contínuo de dados hidrológicos e meteorológicos em toda a extensão da bacia. Isso inclui a medição dos níveis de água, fluxos dos rios, bem como a avaliação da qualidade da água e a previsão de variáveis hidrológicas, permitindo uma compreensão das condições hídricas e a identificação de padrões e variações climáticas (BETTENCOURT *et al.*, 2016; CEARÁ, 2009a; CEARÁ, 2009b; RIBEIRO, 2017). Nesse contexto, a melhoria da eficácia do sistema de apoio à decisão está intrinsecamente interligada à modelagem meteorológica e às previsões de precipitação e vazão nas diferentes escalas de tempo (FILHO, 2006; TUNDISI, 2006).

As previsões de vazão são classificadas em três categorias distintas: curto, médio e longo prazo. As previsões de curto prazo têm como foco horizontes de até duas semanas, enquanto as previsões de longo prazo (sazonal) abrangem períodos mais extensos, variando entre 3 a 6 meses. As previsões de médio prazo (sub-sazonais), situam-se num espaço intermediário entre as previsões de curto e longo prazo. Especificamente, as previsões sub-sazonais abrangem horizontes temporais que se estendem além das previsões imediatas, embora ainda se mantenham num intervalo inferior às previsões sazonais.

As previsões sub-sazonais são consideradas difíceis de serem realizadas, pois trata-se de um período longo, visto que a maioria das condições iniciais de tempo se perdem, e, ao mesmo tempo, de um período curto para serem influenciadas pela variabilidade oceânica (VITART; ROBERTSON, 2018).

Na BHSF, o Operador Nacional do Sistema Elétrico (ONS) emprega as projeções de vazão como base para a condução de um conjunto de atividades estratégicas. Dentre elas, destacam-se a elaboração do planejamento anual para prevenção de cheias, a formulação das diretrizes que regem a operação de controle de enchentes, a geração de cenários de aflúncias, a atualização contínua de dados técnicos referentes aos empreendimentos hidroelétricos, o aprimoramento das informações sobre restrições hidráulicas pertinentes a esses empreendimentos, bem como para avaliar o processo de enchimento dos reservatórios (ONS, 2015).

Já nas bacias hidrográficas localizadas no Estado do Ceará, os modelos hidrológicos, auxiliam a Companhia de Gestão dos Recursos Hídricos (COGERH) na análise da vazão que

aflui aos açudes monitorados, na regularização das vazões, na gestão dos recursos hídricos em períodos de escassez hídrica e nos estudos relacionados a outorga de direitos de uso da água (CARDOSO *et al.*, 2006).

Apesar das evoluções contínuas observadas nos modelos hidrológicos, ainda há espaço para aperfeiçoamento das previsões. A medida que novas técnicas e dados emergem, o refinamento das metodologias existentes pode oferecer ganhos significativos na precisão e aplicabilidade dessas ferramentas essenciais para a gestão e preservação dos recursos hídricos.

Diante desse contexto, torna-se fundamental o desenvolvimento de abordagens inovadoras para a previsão de vazões em escala sub-sazonal, com o intuito de fornecer informações antecipadas e precisas sobre os padrões de fluxo d'água na região. A previsão de vazões desempenha um papel crucial na gestão sustentável dos recursos hídricos, capacitando o planejamento estratégico e enriquecendo a tomada de decisões por meio da incorporação de informações de diversas fontes.

1.2 Objetivos

O objetivo principal deste trabalho é desenvolver uma Rede Neural Híbrida capaz de modelar, em escala sub-sazonal, o processo de transformação de chuva em vazão nas bacias hidrográficas dos reservatórios: Retiro Baixo, Três Marias, Sobradinho, Luiz Gonzaga, Paulo Afonso e Xingó, localizados na BHSF, e nos reservatórios Castanhão, Banabuiú e Orós, situados na bacia do Jaguaribe, no Estado do Ceará. Os objetivos específicos definidos para a área de estudo são:

- Analisar a variabilidade sub-sazonal de precipitações;
- Analisar o desempenho de modelos de previsão sub-sazonal de precipitação;
- Calibrar o modelo hidrológico SMAP em escala diária;
- Avaliar a capacidade de modelos híbridos de Redes Neurais Artificiais (RNAs), baseados em *wavelets*, na previsão de vazões;

1.3 Relevância e Originalidade

O Rio São Francisco é um dos principais cursos d'água do Brasil, desempenhando um papel fundamental no abastecimento de água e na geração de energia elétrica para o país. De acordo com o relatório da Agência Nacional de Energia Elétrica (ANEEL) de 2021, a BHSF

abriga sete usinas hidrelétricas de grande porte, as quais desempenham um papel crucial no fornecimento de energia elétrica para atender as demandas nacionais. Além disso, as sub-bacias do Jaguaribe são especialmente relevantes por abrigarem os principais reservatórios de água do Estado do Ceará, tornando-se uma área estratégica para a gestão dos recursos hídricos na região.

Atualmente, observa-se a existência de uma significativa diferença na qualidade das previsões sub-sazonais em comparação com aquelas realizadas em outras escalas de tempo. Reconhece-se como "gap" ou lacuna o fato de os sistemas de previsão sub-sazonais não atingirem o mesmo nível de precisão e confiabilidade observado nas previsões sazonais. Essa discrepância tem sido objeto de estudo e análise, com o objetivo de aprimorar as previsões sub-sazonais e reduzir a disparidade em relação às previsões sazonais (BOARD *et al.*, 2016).

Os estudos relacionados às previsões de vazões, conduzidos nesta pesquisa, englobam modificações substanciais em um modelo previamente proposto por Freire *et al.* (2019). As contribuições fundamentais deste estudo destacam-se pela adoção de uma arquitetura de RNA distinta, pela ampliação das opções de *wavelets* utilizadas na decomposição das séries temporais, pelo uso simultâneo de todas as séries decompostas como entrada para a rede neural e pela avaliação mensal do desempenho do modelo.

Espera-se que os resultados obtidos por meio da Rede Neural Híbrida possam contribuir para uma gestão mais eficiente dos reservatórios, otimizando o uso dos recursos hídricos, auxiliando no planejamento de atividades agrícolas, hidrelétricas e de abastecimento de água, e proporcionando uma compreensão mais aprofundada das interações entre a precipitação e a vazão na região.

1.4 Estrutura do Trabalho

O presente texto está dividido em 7 capítulos. Após esta introdução, no Capítulo 2, é realizado um estudo sobre a variabilidade espacial e temporal das precipitações na área de estudo. No Capítulo 3, é analisado o desempenho dos modelos numéricos utilizados na previsão de precipitações nas bacias estudadas. No capítulo 4 são apresentados os estudos referentes a calibração do modelo hidrológico SMAP. Nos Capítulos 5 e 6, são desenvolvidos e avaliados modelos de previsão baseados em redes neurais para estimar a vazão na área de estudo. Por fim, no Capítulo 7, são apresentadas as conclusões do trabalho. Finaliza-se este trabalho com as referências e a seção de apêndices.

2 VARIABILIDADE TEMPORAL E ESPACIAL DAS CHUVAS

2.1 Introdução

Desde os primórdios das civilizações, a sobrevivência das sociedades tem sido diretamente influenciada pela sua capacidade de se adaptar às flutuações do clima (MOURA; STUDZINSKI, 1994). Isso é especialmente verdadeiro para populações que habitam regiões suscetíveis a eventos climáticos extremos, como secas e inundações.

A Bacia Hidrográfica do rio São Francisco e a Bacia Hidrográfica do rio Jaguaribe são áreas que enfrentam desafios em decorrência dos efeitos das mudanças climáticas (ROCHA; ALMEIDA, ; MARENGO *et al.*, 2011). A variabilidade temporal e espacial das chuvas nessas regiões afeta diretamente a disponibilidade de recursos hídricos, o que compromete o desenvolvimento de atividades econômicas, tais como a produção de culturas agrícolas e a geração de energia elétrica (MAGALHÃES *et al.*, 2020).

A falta ou o excesso de chuvas podem levar à perda de safras, redução da produtividade e à falência de pequenos agricultores, afetando diretamente a segurança alimentar da população (ALVES *et al.*, 1998; SANTANA; SANTOS, 2020; RODRIGUES, 2016). Além disso, a escassez de água afeta a disponibilidade de recursos hídricos para consumo humano e animal, o que pode levar a problemas de saúde pública e a conflitos sociais (SILVEIRA; SILVA, 2019; MARENGO *et al.*, 2008; MARTINS *et al.*, 2017).

Diante deste cenário, a compreensão e o monitoramento das variáveis climáticas, principalmente em regiões vulneráveis, mostram-se essenciais para o desenvolvimento de estratégias eficazes de adaptação e mitigação dos impactos causados pelas variações do clima. O presente capítulo tem como objetivo analisar a variabilidade temporal e espacial das precipitações, em escala sub-sazonal, nas bacias hidrográficas do Orós, Castanhão, Banabuiú, Xingó, Luiz Gonzaga, Paulo Afonso, Sobradinho, Três Marias e Retiro Baixo.

2.2 Área de Estudo

A Bacia Hidrográfica do rio São Francisco possui uma área de drenagem de 639.219 km^2 , o que corresponde a 8% do território nacional. Estende-se desde Minas Gerais, onde o rio São Francisco nasce, na Serra da Canastra, até o Oceano Atlântico, onde deságua, na divisa dos Estados de Alagoas e de Sergipe. Essa vasta área integra as regiões Nordeste e Sudeste do país,

percorrendo 507 municípios, em seis Estados (Minas Gerais, Goiás, Bahia, Pernambuco, Alagoas e Sergipe), além do Distrito Federal. Constituindo uma das 12 regiões hidrográficas brasileiras, esta bacia foi dividida, para fins de planejamento, em quatro zonas ou regiões fisiográficas: Alto, Médio, Submédio e Baixo São Francisco (BETTENCOURT *et al.*, 2016).

Figura 1 – Área de estudo



Fonte: Elaborado pelo Autor, 2023

O Alto São Francisco compreende uma área de 99.387 km^2 , o que corresponde a 15,6% da área da bacia. Estende-se desde a nascente do rio São Francisco até a cidade de Pirapora, em Minas Gerais, contempla 167 municípios e como principais barragens da bacia destacam-se Três Marias e Retiro Baixo. O Médio São Francisco é o trecho de maior extensão, 401.559 km^2 (63,1 % da bacia). Em seus limites estão contidos 167 municípios estendendo-se desde a cidade de Pirapora até Remanso no Estado da Bahia. Nesta bacia localiza-se a barragem de Sobradinho (BETTENCOURT *et al.*, 2016).

O Submédio São Francisco possui uma área de 115.987 km^2 , abrange 83 municípios, ocupando 18,2% da bacia. Destacam-se neste trecho as represas de Paulo Afonso I, II, III e IV, Luiz Gonzaga e Xingó. Seus limites estendem-se da barragem de Sobradinho até a barragem de Xingó. Já o Baixo São Francisco drena uma área de 19.987 km^2 o que representa 3,1% da bacia e abrange 86 municípios. Corresponde ao trecho a jusante da represa de Xingó até a foz no oceano Atlântico (BETTENCOURT *et al.*, 2016).

A bacia do rio Jaguaribe encontra-se majoritariamente inserida no Estado do Ceará, distribuindo-se em uma área de aproximadamente 74.000 km^2 , com uma pequena parcela estendendo-se ao sul para o Estado de Pernambuco. Esta bacia é dividida em cinco sub-bacias: Alto, Médio e Baixo Jaguaribe, Banabuiú e Salgado, sendo objeto de estudo desta pesquisa as regiões do Alto, Médio Jaguaribe, sub-bacia do salgado e do Banabuiú.

Das cinco sub-bacias que compõem a bacia do Jaguaribe, a sub-bacia do Alto Jaguaribe é a que possui a maior região hidrográfica, composta por 24 municípios, drena uma área de 24.538 km^2 o que equivale a aproximadamente 16% do território cearense. Limita-se a oeste com o Estado do Piauí e ao sul com o Estado de Pernambuco. Seu principal reservatório é o açude Orós, com capacidade de $1.940.000.000 \text{ m}^3$ é responsável por 70% do total de água acumulada nesta sub-bacia (CEARÁ, 2009a).

A sub-bacia do Médio Jaguaribe faz fronteira com todas as demais sub-bacias do Jaguaribe, localiza-se na porção leste do Estado do Ceará e limita-se, em sua porção oriental, como o Estado do Rio Grande do Norte. Esta sub-bacia drena uma área de 10.335 km^2 , abrange 16 municípios do Estado do Ceará, sendo 9 pertencentes de forma integral à sub-bacia e 7 parciais. Sua área equivale a 7% do território cearense. O principal reservatório desta sub-bacia é o açude Castanhão, com capacidade para $6.700.000.000 \text{ m}^3$, responsável por mais de 97% do total de armazenado nesta sub-bacia, é o maior reservatório do Estado do Ceará (CEARÁ, 2009b).

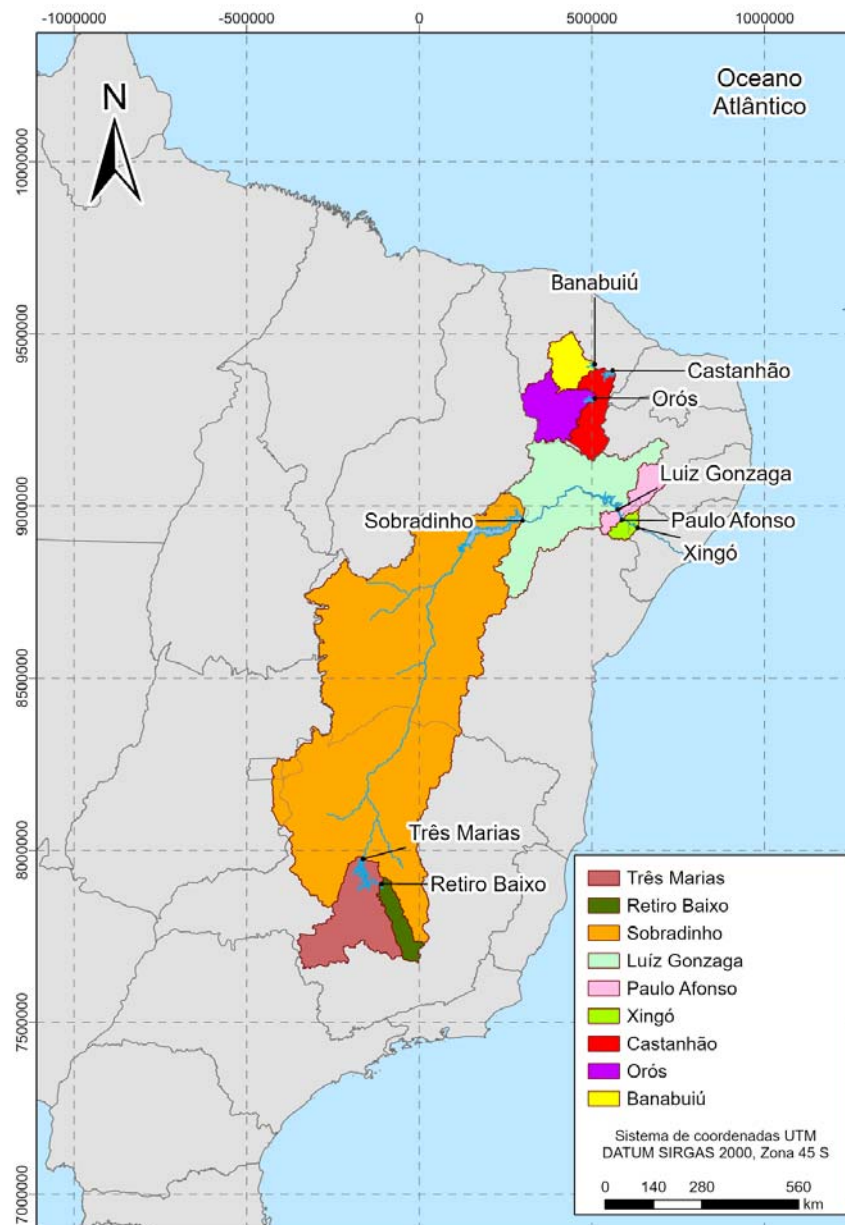
A sub-bacia do rio Salgado está localizada na porção meridional do Estado do Ceará. Limita-se a oeste com a sub-bacia do Alto Jaguaribe, ao sul com o Estado de Pernambuco, ao leste com o Estado da Paraíba e a nordeste com a sub-bacia do Médio Jaguaribe. O principal rio desta sub-bacia é o rio Salgado que possui uma extensão de 308 km e drena uma área de $12.623,89 \text{ km}^2$, abrangendo 24 municípios, sendo 23 integralmente, o equivalente a 9% do território cearense (RIBEIRO, 2017).

A sub-bacia do Banabuiú, por sua localização central, limita-se com quase todas as bacias hidrográficas do Estado e compreende, essencialmente, os sertões centrais do Ceará mais

fortemente submetidos aos rigores do semiárido. Composta por 15 municípios, tem uma área de drenagem de 19.316 km^2 , correspondendo a 13,37% do território cearense. O rio Banabuiú é o mais importante desta sub-bacia e é barrado pelo açude Banabuiú com capacidade para $1.601.000.000 \text{ m}^3$.

Na Figura 2 é possível visualizar a localização dos reservatórios estudados, bem como suas respectivas bacias hidrográficas. As massas de água presentes na área de interesse representam os açudes Banabuiú, Castanhão e Orós, o rio São Francisco e alguns de seus afluentes mais significativos.

Figura 2 – Bacias e reservatórios estudados



Fonte: Elaborado pelo Autor, 2023

2.3 Modos de variabilidade

Os modos de variabilidade são conexões climáticas entre diferentes regiões do mundo que se estabelecem por meio de padrões de circulação atmosférica e oceânica que se estendem por grandes áreas. Esses padrões de circulação são influenciados por oscilações do clima, como a variabilidade interanual do El Niño-Oscilação Sul (ENOS), o Índice do Atlântico Tropical Norte (TNA), o Índice do Atlântico Tropical Sul (TSA), Oscilação Madden-Julian (OMJ), entre outros (NIGAM *et al.*, 2003).

Os modos de variabilidade podem afetar a temperatura, a precipitação, a circulação atmosférica e oceânica em diferentes partes do mundo, e sua compreensão é fundamental para aprimorar a previsão do tempo e entender como as mudanças climáticas afetam diferentes regiões do mundo (LI *et al.*, 2011). Uma breve descrição de dois dos principais modos de variabilidade que influenciam o clima nas bacias analisadas são apresentados a seguir.

El Niño Oscilação Sul (ENOS)


O fenômeno El Niño Oscilação Sul (El Niño Oscilação Sul (ENOS)) é compreendido como uma das principais fontes de variabilidade climática interanual global (CAVALCANTI, 2016). O ENOS tende a ocorrer em intervalos de 2 a 7 anos e se manifesta por alternâncias entre dois extremos chamados de El Niño e La Niña. Uma vez iniciada, esta oscilação tende a durar de 18 a 24 meses (PHILANDER, 2018).

O ENOS é um fenômeno de grande escala que acontece no oceano Pacífico. O fenômeno refere-se a uma combinação de dois mecanismos que demonstram o acoplamento existente entre o oceano e a atmosfera. O El Niño / La Niña (EN) representa a componente oceânica, enquanto que a Oscilação Sul (OS) representa a contrapartida atmosférica. O ENOS refere-se às situações nas quais o oceano Pacífico Equatorial está mais quente (El Niño) ou mais frio (La Niña) do que a média histórica. Essa oscilação produz alterações na temperatura do mar, na pressão, no vento e na convecção tropical, principalmente no oceano Pacífico, mas com reflexos em muitas regiões do planeta, incluindo o NEB (MENDONÇA; DANNI-OLIVEIRA, 2017).

Por padrão as águas do Pacífico tropical encontram-se mais frias na região leste e mais quentes no extremo oposto, na região oeste (MENDONÇA; DANNI-OLIVEIRA, 2017). Esta distribuição de temperatura da superfície do mar, associada a campos de pressão, influenciam

a circulação geral da atmosférica (Figura 3), gerando ascensão de ar na parte oeste do Pacífico tropical e descida de ar na parte leste, movimento este denominado na literatura como célula de Walker (LORENZ, 1967). Esta configuração propicia frequentes chuvas na parte oeste, nas proximidades da Indonésia e costa da Austrália e inibe a formação de chuvas no extremo oposto, costa oeste (CUNHA *et al.*, 2011).

Figura 3 – Célula de Walker durante ENOS neutro




Fonte: Adaptada de Collins (2014)

Em eventos de El Niño (Figura 4), observa-se previamente ao estabelecimento do fenômeno, um enfraquecimento dos ventos alísios sobre o Pacífico Equatorial. Este fato altera o padrão de circulação oceânica, inibe a ressurgência de águas frias no leste do Pacífico tropical e gera um deslocamento das águas quentes do oeste para uma posição mais a leste. Com o deslocamento cada vez mais para leste, as águas anormalmente quentes do Oceano Pacífico tropical chegam a atingir a costa da América do Sul, nas proximidades do Peru e Equador. Desse modo, passa a ocorrer ascensão de ar nessa região. As chuvas que eram mais frequentes no pacífico oeste, desta vez tornam-se mais frequentes, principalmente, no pacífico leste, na costa oeste da América do Sul (CUNHA *et al.*, 2011; CAVALCANTI, 2016; GLANTZ *et al.*, 1991).

Em eventos de La Niña, observa-se um aumento na intensidade dos ventos que sopram de leste para oeste (ventos alísios) em baixos níveis da atmosfera. Como resultado, as águas a oeste do Pacífico tendem a aquecer mais que o normal, enquanto as águas do Pacífico leste tornam-se mais frias que o normal. Este fenômeno causa um alongamento na célula de Walker, em que é observado um represamento de águas quentes mais a oeste do Pacífico, gerando mais evaporação e, conseqüentemente, mais chuvas nessa região oeste do Pacífico. As áreas do Pacífico leste, em eventos de La Niña, tende a experimentar períodos com menor frequência de chuvas (CAVALCANTI, 2016).

Figura 4 – Célula de Walker durante eventos de El Niño e La Niña



Fonte: Adaptada de Collins (2014)

Além de índices baseados nos valores da temperatura da superfície do mar no oceano Pacífico equatorial, o fenômeno ENOS pode ser também quantificado pelo Índice de Oscilação Sul (IOS). Este índice representa a diferença entre a pressão ao nível do mar entre o Pacífico central (Taiti) e o Pacífico do oeste (Darwin/Austrália) (CUNHA *et al.*, 2011). Em episódios do El Niño, observa-se IOS negativo, o que significa que há menor pressão sobre o Taiti e maior pressão em Darwin. Os episódios de La Niña, apresentam IOS positivo, significando que há maior pressão no Taiti e menor em Darwin (CUNHA *et al.*, 2011; CAVALCANTI, 2016).

A Zona de Convergência Intertropical (ZCIT) é apontada como um dos principais mecanismos de grande escala responsável pelas precipitações no NEB, este mecanismo pode ser influenciado pelo ENOS devido as alterações na circulação atmosférica em escala global causada pelo fenômeno (MOLION; BERNARDO, 2002).

A redução da precipitação no NEB está diretamente relacionada à posição da ZCIT, área de convergência de ventos alísios que favorecem a formação de chuvas nessa região. Durante um evento El Niño, a posição da ZCIT pode se deslocar para o norte, desfavorecendo a ocorrência de chuvas na região Nordeste do Brasil. Por outro lado, durante um evento La Niña, a posição da ZCIT tende a posicionar-se mais ao sul, aumentando a ocorrência de chuvas na região Nordeste do Brasil (ARAÚJO *et al.*, 2013).

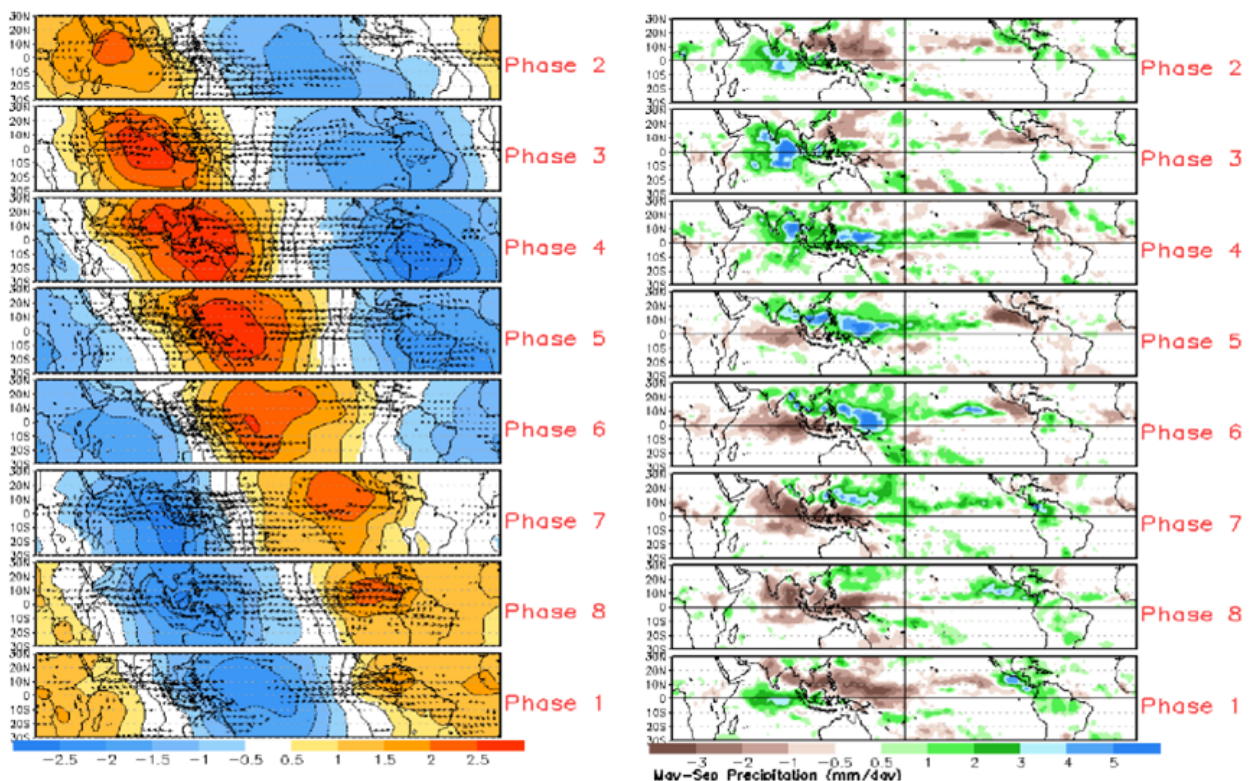
Oscilação Madden - Julian (OMJ)

A OMJ é um modo de variabilidade climática intrassazonal que ocorre com período de 30 a 60 dias. Esse fenômeno se caracteriza pela movimentação de áreas de convecção (ascendência de ar úmido e quente) e áreas de inibição de convecção (descendência de ar seco e frio) ao longo do equador, predominantemente nas regiões tropicais dos Oceanos Índico e Pacífico. A OMJ se destaca por seu efeito na configuração dos ventos, padrões de nuvens e

distribuição de chuvas, que percorrem o hemisfério equatorial (MADDEN; JULIAN, 1971; HENDON; SALBY, 1994; ZHANG, 2005)..

Essa oscilação normalmente se inicia no Oceano Índico como uma grande área de convecção que gera chuvas acima do normal na região, essa convecção com o passar dos dias se desloca para leste, chegando ao Oceano Pacífico Oeste, gerando chuvas no norte da Austrália e na Indonésia. Como a atmosfera é um fluido, qualquer perturbação nela é propagada, então a perturbação gerada pela convecção acaba se propagando pelo restante do globo, atravessando o Pacífico, a América do Sul, o Oceano Atlântico e o continente africano, até retornar para o Oceano Índico (MADDEN; JULIAN, 1971; ZHANG, 2005).

Figura 5 – Anomalias do potencial de velocidade do vento a 850 hPa e de precipitações



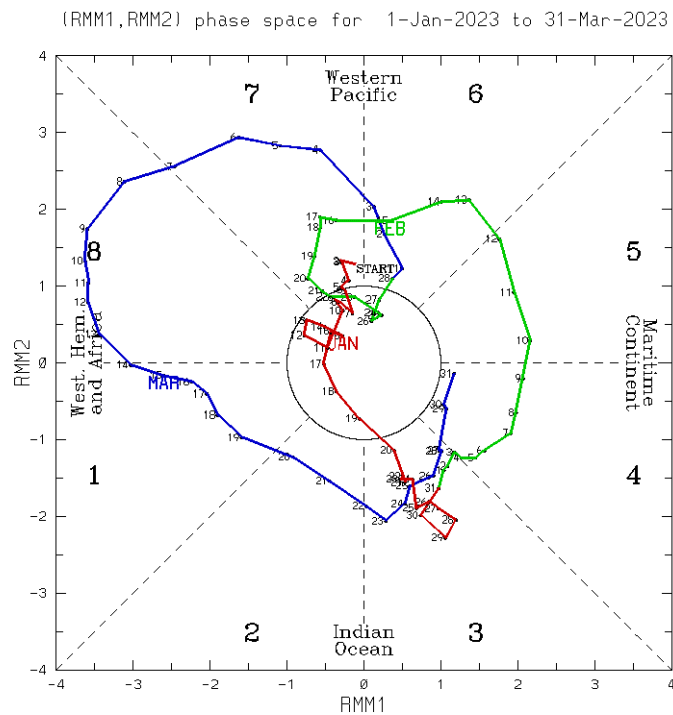
Fonte: Gottschalck *et al.* (2004)

A evolução da OMJ pode ser dividida em oito fases, como ilustrado nas Figuras 5 e 6. Cada fase possui uma duração média de aproximadamente 6 dias e é determinada com base nos índices *RMM1* e *RMM2* (*Real-time Multivariate MJO*). Esses índices são calculados a partir dos dois primeiros componentes principais do Fluxo de Radiação de Onda Longa (OLR), vento zonal a 850 hPa e vento zonal a 200 hPa, em uma região que abrange as latitudes entre 15°S e 15°N (WHEELER; HENDON, 2004).

A OMJ altera as áreas de movimentos ascendentes e subsidentes e por vezes favorece

ou desfavorece a formação de chuvas em diversas regiões. Seus efeitos já foram observados na variabilidade da precipitação nas ilhas do Pacífico, nas regiões de monções da Ásia (LAU; CHAN, 1986) e Austrália (HENDON *et al.*, 2000), ao longo da costa oeste da América do Norte (JONES, 2000; MO; HIGGINS, 1998), na América do Sul (PAEGLE *et al.*, 2000; JUNIOR *et al.*, 2021; VALADÃO *et al.*, 2017), e na África (MATTHEWS, 2004).

Figura 6 – Diagrama das fases da OMJ



Fonte: Bureau of Meteorology

No Brasil, os efeitos da OMJ podem ser observados principalmente nas regiões Norte e Nordeste, resultando em uma série de impactos. A magnitude desses impactos depende da fase da oscilação e pode causar eventos de precipitações irregulares, alternando entre períodos secos e chuvosos (VALADÃO *et al.*, 2017; JUNIOR *et al.*, 2021; SHIMIZU *et al.*, 2017).

Quando a área de convecção mais intensa está posicionada próxima à Indonésia, movimentos subsidentes anômalos ocorrem sobre o Norte e Nordeste do Brasil, inibindo a formação de chuvas. Quando os movimentos subsidentes estão inibindo a formação de chuvas sobre a Indonésia, uma área de movimentos ascendentes favorece a formação de chuvas no Brasil (VALADÃO *et al.*, 2017; SOUZA; AMBRIZZI, 2006; VALADÃO *et al.*, 2015).

2.4 Transformada *Wavelets*

A análise de séries temporais, pode ser definida como sendo uma tentativa de extrair um resumo significativo e informações estatísticas de pontos de dados organizados em ordem cronológica. Tal análise é feita a fim de diagnosticar comportamentos passados e prever comportamentos futuros. De modo geral pode ser resumida à questão de causalidade: como o passado influencia o futuro? (NIELSEN, 2019)

As transformações matemáticas, tais como: Transformada de Fourier e Transformada de *wavelets* podem ser utilizada para decompor um sinal em subconjuntos para representar o comportamento da série em diferentes escalas de frequência e tempo a fim de detectar comportamentos periódicos.

Enquanto a transformada de Fourier decompõe séries em funções de seno e cosseno, a transformada de *wavelets* decompõe a série em funções ortogonais. Como a transformada de Fourier decompõe as séries de forma contínua, ela é ideal para análise de séries estacionárias o que não é o caso das séries hidrológicas. Outra desvantagem no uso da análise de Fourier provém do fato de que ela apresenta apenas resolução de frequência e não no tempo. Isto significa que, embora capaz de determinar o conteúdo de frequência presente em um sinal, não pode-se saber quando ocorrem. Portanto, na análise de sinais não estacionários, a transformada de *wavelets* é considerada mais apropriada (OLIVEIRA, 2007).

Uma *wavelets* é definida como sendo um conjunto de pequenas ondas (ondeletas) geradas por translações e escalonamentos de uma função geradora ψ , *wavelets*-mãe, dando origem a *wavelets*-filhas (2.1)

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right), a, b \in \mathbb{R}, a > 0 \quad (2.1)$$

Em que a representa o fator de escalonamento, entendido como sendo o processo de compressão e dilatação do sinal. O termo b representa o fator de translação, corresponde à informação de tempo no domínio da transformada. O termo $\frac{1}{\sqrt{a}}$ corresponde a um fator de normalização para que a energia seja preservada em uma dada região do espaço. A transformação é feita para diferentes valores de a e b fazendo com que a série seja decomposta em componentes no tempo e frequência de acordo com os parâmetros utilizados (MORETTIN, 1999).

Esta transformação pode ser do tipo contínua ou discreta. Para as análises realizadas neste trabalho utiliza-se a transformação discreta, considerada ideal para a análise de sinais, a qual será descrita a seguir.

2.4.1 Transformada wavelets discreta (TWD)

Segundo Morettin (1999) quando se trabalha com dados de valores discretos, para o cálculo da Transformada de *Wavelets* Discreta (TWD), os fatores de escalonamento a e o de translação b , são escolhidos com base em potência de 2, o que é referenciado como escalonamento diático.

Neste caso a e b assumem: $a = 2^{-j}$, $b = k \cdot 2^{-j}$, com j e $k \in \mathbb{R}$. Substituindo na Equação 2.1, obtêm as *wavelets* $\psi_{j,k}(t)$, geradas a partir da *wavelets*-mãe, dada por:

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k), j, k \in \mathbb{Z} \quad (2.2)$$

Na Equação 2.2, $\psi_{j,k}(t)$ é obtida de $\psi(t)$ por uma dilatação binária 2^j e uma translação diática $k2^{-j}$.

As funções $\psi_{j,k}(t)$ representadas pela Equação 2.2 formam bases que não são necessariamente ortogonal, no entanto a vantagem de se trabalhar com bases ortogonais é a possibilidade de se obter uma reconstrução perfeita do sinal original a partir dos coeficientes da transformada. Desta forma, considera-se na análise, bases de *wavelets* que sejam ortogonais (MORETTIN, 1999; OLIVEIRA, 2007).

Considere a seguinte base ortonormal gerada por $\psi(t)$:

$$\langle \psi_{j,k}, \psi_{l,m} \rangle = \delta_{j,l} \delta_{k,m}, j, k, l, m \in \mathbb{Z}, \quad (2.3)$$

de tal modo que, para qualquer $f(t)$ de quadrado integrável sobre \mathbb{R} , tem-se que:

$$f(t) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} c_{j,k} \psi_{j,k}(t) \quad (2.4)$$

Pode-se dizer que a Equação 2.4 é uma série de *wavelets* de $f(t)$ e os coeficientes *wavelets* $c_{j,k}$ são dados por:

$$c_{j,k} = \langle f, \psi_{j,k} \rangle = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt \quad (2.5)$$

Uma outra forma de gerar as *wavelets* é através da chamada função escala $\phi(t)$, ou *wavelets*-pai. Sua solução é apresentada na equação a seguir.

$$\phi(t) = \sqrt{2} \sum_k \ell_k \phi(2t - k) \quad (2.6)$$

Segundo Morettin (1999) essa função gera uma família ortonormal em $L^2(\mathbb{R})$, dada por:

$$\phi_{j,k}(t) = 2^{j/2} \phi(2^j t - k), j, k \in (\mathbb{Z}) \quad (2.7)$$

Desta forma, ψ pode ser obtida por intermédio de ϕ , por:

$$\psi(t) = \sqrt{2} \sum_k h_k \phi(2t - k) \quad (2.8)$$

de modo que:

$$h_k = (-1)^k \ell_{1-k} \quad (2.9)$$

Os coeficientes ℓ_k e h_k são denominados filtros, também conhecidos como filtros passa-baixa (*low-pass*) e passa-alta (*high-pass*), respectivamente, usados para calcular a TWD. Esses coeficientes são dados por:

$$\ell_k = \sqrt{2} \int_{-\infty}^{\infty} \phi(t) \phi(2t - k) dt, \quad (2.10)$$

$$h_k = \sqrt{2} \int_{-\infty}^{\infty} \psi(t) \phi(2t - k) dt. \quad (2.11)$$

Considerando o sistema ortonormal $\{\phi_{j,k}(t), \psi_{j,k}(t)\}$, qualquer função $f(t) \in L^2(\mathbb{R})$ pode ser escrita pela seguinte expressão:

$$f(t) = \sum_k cA_{j_0,k} \phi_{j_0,k}(t) + \sum_{j \geq j_0} \sum_k cD_{j,k} \psi_{j,k}(t) \quad (2.12)$$

sendo cA e cD denominados coeficientes de aproximação e de detalhes de *wavelets*, respectivamente. O termo j_0 representa a escala mais suave (MORETTIN, 1999; OLIVEIRA, 2007).

2.4.2 Wavelets como filtro de passagem

A transformada *wavelets* pode ser definida como uma sequência de aplicações dos filtros de passa-alta e passa-baixa, dando origem a árvore de decomposição de *wavelets* gerando componentes de aproximação e componentes de detalhes, permitindo assim uma melhor visualização do comportamento fundamental da série (MORETTIN, 1999; OLIVEIRA, 2007).

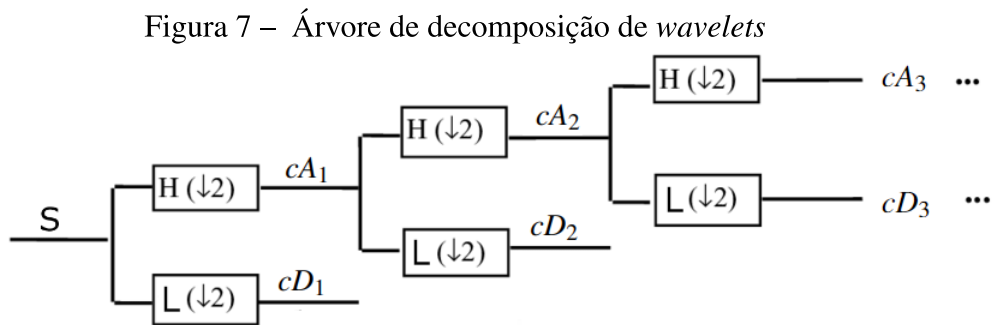
Inicialmente o sinal é submetido a um banco de filtros passa-alta e passa-baixa. Os componentes resultantes da filtragem passa-alta, contém as altas frequências e são denominados coeficientes de detalhes, comumente representados por cD_1 . A componente resultante do filtro passa-baixa são chamadas de coeficientes de aproximação, representadas por cA_1 . Tais coeficientes precisam ser analisados com mais cuidado, visto que fornecem apenas uma visão global destas frequências.

Passa-se então os coeficientes de aproximação cA_1 pelos filtros de passa-alta e passa-baixa. Da mesma maneira supracitada, tal procedimento dá origem a dois novos coeficientes

cA_2 e cD_2 . Os coeficientes submetidos ao filtro passa-alta, fornece detalhes, enquanto que os coeficientes que foram submetidos ao filtro passa-baixa, são submetidos mais uma vez a passagem dos filtros.

O processo segue iterando sempre sobre os coeficientes de aproximação do nível anterior, de modo que o sinal é dividido em várias componentes de baixa resolução. O processo de decomposição é aplicado até que o ultimo nível de detalhes contenha apenas uma amostra. No entanto, o limite prático de decomposição costuma ser selecionado com base na natureza do sinal (FREIRE *et al.*, 2012; OLIVEIRA, 2007; MORETTIN, 1999)

A Figura 7, ilustra a árvore de decomposição de *wavelets*, onde L indica o filtro passa-baixa, H o filtro passa-alta e $\downarrow 2$ indica a operação de decimação por 2, ou seja, a cada duas saídas do filtro, uma é desprezada.



Fonte: Próprio autor.

A TWD emprega dois tipos de funções, chamadas de funções escala e funções *wavelets* representadas pela Equação 2.4, que por sua vez estão associadas aos filtros de passa-alta e passa-baixa conforme descrito pelas Equações 2.11 e 2.11, respectivamente. A decomposição do sinal em bandas de diferentes frequências é simplesmente obtida pela filtragem sucessiva do sinal (OLIVEIRA, 2007).

O processo de reconstrução do sinal é realizado a partir dos coeficientes cA e cD . Por exemplo, o sinal bruto (S) da Figura 7 é formado pelos coeficientes de aproximação e de detalhe do primeiro nível ($S = cA_1 + cD_1$); a aproximação do primeiro nível cA_1 , pode ser representada por $cA_1 = cA_2 + cD_2$; já o sinal bruto S pode ser reconstruído somando o coeficiente de aproximação do último nível de decomposição com os coeficientes de detalhes dos níveis anteriores ($S = cA_3 + cD_3 + cD_2 + cD_1$) (MORETTIN, 1999).

2.4.3 Famílias Wavelets

Conforme descrito anteriormente, uma *wavelet* é definida como sendo um conjunto de pequenas ondas geradas a partir de uma função geradora denominada *wavelets*-mãe. Na literatura pode-se encontrar um grande número de funções que podem ser eleitas como *wavelets*-mãe e sua escolha é de fundamental importância para o bom desempenho da transformada (OLIVEIRA, 2007; MORETTIN, 1999; TORRENCE; COMPO, 1998).

Segundo Morettin (1999) para que uma função matemática possa ser considerada uma *wavelet* ela deve satisfazer as seguintes propriedades:

$$(P1) \int_{-\infty}^{\infty} \psi(t) dt = 0$$

Esta propriedade é conhecida como condição de admissibilidade e permitem que as *wavelets* apresentem características oscilatórias ao longo do eixo temporal.

$$(P2) \int_{-\infty}^{\infty} |\psi(t)| dt < \infty$$

Esta propriedade é conhecida como condição de regularidade e garante que a função *wavelets* tenha sua energia localizada em uma certa região.

$$(P3) \int_{-\infty}^{\infty} |\psi(t)|^2 dt = 1$$

A propriedade 3, referenciada em Castillo *et al.* (2012) por energia unitária, garante que a função *wavelets* possua suporte compacto, ou com um decaimento rápido de amplitude, conhecido como suporte efetivo, garantindo a localização espacial.

(P5) Os primeiros $r - 1$ momentos de ψ anulam-se, isto é, $\int_{-\infty}^{\infty} t^j \psi(t) dt = 0, j = 0, 1, \dots, r - 1$, para algum $r \geq 1$ e $\int_{-\infty}^{\infty} |t^r \psi(t)| dt < \infty$.

Em que o valor de r está relacionado ao grau de suavidade (regularidade) de ψ . Quanto maior o valor de r mais suave será ψ (MORETTIN, 1999).

Segundo Torrence e Compo (1998), a escolha da *wavelets*-mãe deve ser baseada nas características do sinal que se deseja decompor, ou seja, o sinal modular da *wavelets*-mãe

deve refletir as características do sinal analisado. Entre as famílias de *wavelets* encontradas na literatura, pode-se citar as *wavelets* de Daubechies, Symlet, Coiflet, Meyer e Morlet (OLIVEIRA, 2007).

As *wavelets* Daubechies são uma das mais utilizadas no tratamento de sinais. Elas representam uma coleção de *wavelets*-mãe ortogonais com suporte compacto, caracterizadas por um número máximo de momentos de desaparecimento para um determinado comprimento do suporte. Por exemplo, a *wavelet* Daubechies de ordem 1 (db1), que também é conhecida como *wavelet* de Haar, tem um momento de desaparecimento, a db2 tem dois momentos de desaparecimento, e assim por diante (FREIRE *et al.*, 2012).

A *wavelet* mãe Coiflet é uma variação da *wavelet* mãe Daubechies, possui uma resposta em frequência mais suave em comparação com outras *wavelets*, possui um suporte finito e é uma função de alta ordem, o que significa que ela pode ser usada para representar sinais com diferentes graus de complexidade. A *wavelet* mãe Coiflet é amplamente utilizada em aplicações que exigem uma resposta em frequência mais suave, como na análise de sinais de áudio e imagem (STRANG; NGUYEN, 1996).

A *wavelet* mãe Symlet é uma generalização da família de *wavelets* Daubechies. Apresenta uma resposta em frequência que é semelhante à da *wavelet* mãe Daubechies, mas possui uma simetria adicional que ajuda a minimizar o efeito das bordas. Devido a esta característica, esta *wavelet* é considerada uma boa escolha para aplicações de processamento de sinal que envolvem a detecção de bordas, como análise de sinais biológicos (STRANG; NGUYEN, 1996).

A *wavelet* mãe de Meyer é uma função simétrica, contínua e com suporte compacto, com capacidade de se adaptar a diferentes escalas e frequências de um sinal. Ela tem um suporte mais longo do que outras *wavelets*, o que permite representar sinais com mais detalhes de alta frequência. Por conta dessas características, é amplamente utilizada em compressão de imagens médicas, detecção de falhas em estruturas de engenharia civil e análise de séries temporais (STRANG; NGUYEN, 1996).

A *wavelet* mãe de Morlet, também conhecida como Chapéu Mexicano, é uma *wavelet* de suporte contínuo e simétrica, com formato de sino invertido. Ela é caracterizada por ter uma resposta em frequência suave e uma alta capacidade de representar detalhes de alta frequência em sinais. Essa *wavelet* é amplamente utilizada em aplicações que envolvem análise de sinais com variações abruptas de frequência, como oscilações em séries temporais (STRANG; NGUYEN,

1996).

Informações mais detalhadas sobre as propriedades e formulações matemáticas das *wavelets* mencionadas podem ser encontradas em Strang e Nguyen (1996).

2.5 Metodologia

Os dados utilizados neste estudo consistem em médias diárias de precipitação nas bacias em questão. Essas médias foram calculadas utilizando o método de *Thiessen*, a partir da base de dados pluviométricos da Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) e da Agência Nacional de Águas (ANA). As séries temporais abrangem o período de 1974 a 2021.

Transformada Wavelets

Para investigar as tendências na série temporal de precipitação e obter uma análise mais completa do comportamento dessa variável ao longo do tempo, utilizou-se a técnica de análise por transformada *wavelet*.

A transformada *wavelet* é uma técnica de análise de sinais que permite extrair informações sobre a frequência e a localização no tempo de padrões presentes em uma série temporal (MALLAT, 1999). Esta técnica tem sido amplamente utilizada em diversas áreas do conhecimento, desde a análise de sinais biomédicos e de engenharia até a análise de séries temporais climáticas (TORRENCE; COMPO, 1998).

Dentre as funções *wavelet*, a *wavelet* de Morlet é particularmente adequada para detectar padrões em séries temporais com comportamento oscilatório e foi aplicada em várias áreas da pesquisa climática (TAN *et al.*, 2016; RATHINASAMY *et al.*, 2019; ANDREOLI *et al.*, 2004).

A *wavelets* de Morlet pode ser definida como sendo o produto de uma onda senoidal complexa e uma janela gaussiana dada por:

$$\psi(t) = \frac{1}{\sqrt[4]{\pi}} e^{jw_0 t} e^{-\frac{t^2}{2}} \quad (2.13)$$

Em que $\psi(t)$ representa a *wavelet* de Morlet, função matemática que varia com o tempo e a frequência. $\frac{1}{\sqrt[4]{\pi}}$ é uma constante de normalização que garante que a energia total da *wavelet* seja igual a 1. $e^{jw_0 t}$ é um fator de fase complexo que varia com a frequência w_0 e

com o tempo t . Ele é responsável por capturar informações de fase do sinal. $e^{-\frac{t^2}{2}}$ é uma função gaussiana centrada em $t = 0$, que é responsável por filtrar o sinal de entrada em uma banda de frequência específica. A largura da banda é controlada pelo parâmetro w_0 e determina a resolução temporal e espectral da *wavelet* de Morlet.

A *wavelet* de Morlet foi escolhida, pois ao ser aplicada na série de precipitação, permite identificar as escalas temporais onde as tendências mais relevantes estão presentes, tornando possível avaliar a intensidade dessas tendências. O método é capaz de destacar a presença de tendências de longo prazo, bem como oscilações de curto prazo (MORETTIN, 1999).

Também foi calculado o espectro de energia local, que é uma medida da variação da série temporal em cada escala de tempo. Ele é calculado a partir do quadrado do valor absoluto do coeficiente da transformada *wavelet*. A média temporal do espectro de energia local em cada escala produz o espectro de potência global, que indica a distribuição da energia em diferentes frequências na série temporal (TORRENCE; COMPO, 1998).

O Cone de influência é uma região no espectro de energia local em que os efeitos de borda são significativos, ou seja, é a região em que a análise pode ser afetada por pontos de dados nas bordas da série temporal. Ele é determinado pelo tempo de decaimento da autocorrelação do espectro de energia local em cada escala (TORRENCE; COMPO, 1998).


A transformada *wavelet* foi realizada utilizando o pacote *PyWavelets* em *Python*. Mais detalhes sobre a *wavelets* de Morlet podem ser encontrados em Torrence e Compo (1998).

Modos de variabilidade

A Identificação das fases da OMJ baseou-se em uma série histórica obtida por meio do Sistema de Monitoramento dos Padrões de Teleconexão na América do Sul, mantido pelo Centro de Ciências Atmosféricas da Universidade Federal de Itajubá (UNIFEI). A série de dados utilizada no estudo da OMJ abrange o período de 1974 a 2021 e contém informações sobre a fase, magnitude da oscilação e o índice RMM (*Real-time Multivariate MJO Index*).

Após identificar as diferentes fases da OMJ e determinar seus respectivos períodos de ocorrência, realizou-se o cálculo da média diária de precipitação para cada fase da OMJ. Em seguida, foi feita a subtração dessa média em relação à média climatológica. Esse procedimento teve como objetivo analisar e quantificar as anomalias de precipitação diária associadas às diferentes fases da OMJ. Como a influência da OMJ é mais evidente no verão austral, podendo

Figura 8 – Ocorrência de El Niño e de La Niña.



Fonte: Elaborado pelo Autor, 2023

interferir, desta forma, nas chuvas de pré-estação e no início da estação chuvosa (MONTEIRO¹, 2022), optou-se por analisar apenas os meses dezembro a maio.

A influência da OMJ na variabilidade das precipitações nas bacias estudadas também foi avaliada por meio das proporções de eventos extremos em cada fase da OMJ. Para tanto, foram realizados cálculos das razões entre o número de eventos extremos observados durante uma determinada fase da OMJ e o total de dias compreendidos nessa fase. A definição de precipitação como evento extremo se deu por meio do cálculo do percentil 95 para cada mês em cada bacia hidrográfica. Assim, chuvas iguais ou superiores a esse valor foram consideradas como eventos extremos.

A análise também considerou os períodos em que a OMJ é considerada ativa e inativa. Períodos em que a amplitude da oscilação, representada por $A = \sqrt{RMM1^2 + RMM2^2}$, é inferior a 1 indicam a ausência da OMJ, caracterizando a fase inativa da oscilação (WHEELER; HENDON, 2004).

A avaliação das proporções de eventos extremos nas diferentes fases da OMJ foi realizada considerando também os períodos de ocorrência do fenômeno El Niño e La Niña. Para isso, utilizou-se uma série temporal de anomalias da Temperatura da Superfície do Mar (TSM) na região conhecida como Nino-3.4. A fim de identificar os períodos de El Niño e La Niña, foi calculada uma média móvel trimestral da anomalia da TSM. Quando essa média móvel trimestral foi superior a 0,5°C por cinco períodos consecutivos, foi considerado ocorrência de El Niño. Da mesma forma, quando a média móvel trimestral foi inferior a -0,5°C por cinco meses consecutivos, considerou-se a ocorrência de La Niña. Os períodos identificados como ocorrência de El Niño e La Niña são apresentados na Figura 8.

Após a identificação dos períodos de ocorrência das fases negativa e positiva do

fenômeno ENOS, procedeu-se à investigação da interação entre esses fenômenos e as diferentes fases da OMJ. Para tal, foi realizado o mapeamento desses períodos em relação às fases da OMJ. Posteriormente, foram analisadas as proporções de eventos extremos durante as fases ativas e inativas da OMJ nos períodos de ocorrência de El Niño e La Niña.

2.6 Resultados e discussões

No que se refere a distribuição espacial e temporal das precipitações, devido aos diferentes fenômenos climatológicos que atuam em cada região, há uma grande variabilidade na distribuição pluviométrica ao longo do ano (Figura 9). No geral, as chuvas concentram-se em alguns meses do ano (estação chuvosa), nos demais meses observa-se períodos prolongados com baixos índices pluviométricos.


Com base na Figura 9, é possível constatar que as bacias do Castanhão, Orós e Banabuiú apresentam padrões pluviométricos similares, com períodos chuvosos bem definidos, concentrados nos cinco primeiros meses do ano. Nos meses de março e abril, ocorre um pico nas chuvas, com uma média mensal de aproximadamente 150 mm, destacando-se como os meses mais significativos em termos de volume de precipitação.

Nos meses de junho a novembro, observa-se um período de estiagem prolongada, com baixa incidência de chuvas, com valores inferiores a 25 mm/mês. As precipitações anuais médias nas bacias são de 752 mm para o Castanhão, 683 mm para o Orós e 666 mm para o Banabuiú.

As bacias de Retiro Baixo, Três Marias e Sobradinho também podem ser agrupadas por conter padrões pluviométricos similares. Uma característica marcante dessas bacias é a distribuição espacial da precipitação, com média em torno de 1.400 mm/ano (CAVALCANTI, 2016). As chuvas significativas tem início a partir da primeira quinzena de outubro (ALVES¹ *et al.*, 2005) estendendo-se até março, com totais acumulados superiores a 200 mm/mês. O período de seca vai de maio a setembro, e os totais acumulados nesse período não ultrapassam os 50 mm/mês.

As bacias de Luiz Gonzaga e Paulo Afonso apresentam características temporais semelhantes às bacias do Jaguaribe, porém com precipitações menos expressivas, totalizando uma média anual de aproximadamente 520 mm e 560 mm, respectivamente (BETTENCOURT *et al.*, 2016). Os meses de janeiro a abril se destacam como os períodos de maior incidência de chuvas nessas bacias, com médias mensais variando entre 50 e 100 mm.

Figura 9 – Climatologia da Precipitação mensal.




Fonte: Elaborado pelo Autor, 2023

Por outro lado, na bacia do Xingó, a precipitação média anual é de aproximadamente 590 mm (BETTENCOURT *et al.*, 2016). Nessa região, as chuvas apresentam uma variação relativamente baixa ao longo do ano, com um leve aumento observado entre os meses de março e julho.

Na Figura 10, apresenta-se um gráfico de caixa (*boxplot*) que representa as precipitações mensais nas bacias, considerando apenas os meses em que as chuvas são mais significativas. Para a bacia do Jaguaribe, Luiz Gonzaga e Paulo Afonso, foram considerados os meses de janeiro a abril. Já na bacia do Xingó, o período considerado foi entre março e julho. Para as bacias de Retiro Baixo, Sobradinho e Três Marias, foram considerados os meses de novembro a março.

Conforme, discutido anteriormente, na Figura 10 pode-se observar as bacias de Três Marias, Retiro Baixo e Sobradinho com maiores índices pluviométricos na estação chuvosa, seguido das bacias do Castanhão, Banabuiú e Orós. As bacias de Luiz Gonzaga, Paulo Afonso e Xingó apresentam os menores índices.

Figura 10 – Precipitações mensais na estação chuvosa.



Fonte: Elaborado pelo Autor, 2023

Para as bacias de Três Marias e Retiro Baixo, é observado que o acumulado das precipitações mensais tendem a variar entre 150 mm e 280 mm, com valores médios próximos de 200 mm (representados pelo triângulo verde). Já na bacia de Sobradinho, as variações estão entre 100 mm e 200 mm, com média próxima a 150 mm. A similaridade entre a média e a mediana nessas bacias indica uma distribuição relativamente equilibrada das precipitações ao longo dos meses na estação chuvosa.

Com relação às bacias de Luiz Gonzaga, Paulo Afonso e Xingó observa-se uma menor variabilidade no acumulado das precipitações mensais, quando comparado com as bacias de Três Marias, Retiro Baixo e Sobradinho. Nota-se também uma concentração das precipitações próximas ao limite inferior das caixas. Há também uma presença maior de valores extremos (*ou-*

liers), principalmente na bacia do Xingó, indicando uma maior ocorrência de chuvas extremas, fora do padrão da região.

Por fim, ao analisar as bacias do Orós, Banabuiú e Castanhão, observa-se que a maior parte das chuvas nessa região tendem a ocorrer em intensidades moderadas. Na bacia do Orós e do Castanhão, a maior parte do acumulado mensal na estação chuvosa é inferior a 150 mm, enquanto na bacia do Banabuiú, esse valor fica abaixo de 100 mm. As médias pluviométricas nessas bacias são ligeiramente superiores à mediana e não são observados grandes incidências de períodos com chuvas extremas nessas regiões.

2.6.1 Análises de Wavelet

Como discutido anteriormente no Tópico 2.4, a Transformada de Fourier pode ser imprecisa e ineficiente ao localizar a relação entre tempo e frequência em muitas séries temporais, incluindo as séries de precipitação. Isso se deve ao fato de que tais séries são geralmente não-estacionárias e contêm eventos irregulares distribuídos em diferentes frequências e potências. A Transformada *Wavelets*, por sua vez, é capaz de analisar a periodicidade desses eventos em diferentes escalas de variabilidade temporal e não requer uma série estacionária para a análise, tornando-se assim uma ferramenta eficaz na análise de sinais climáticos (DAUBECHIES, 1990).

Com o objetivo de compreender a variabilidade das precipitações ao longo do tempo, foi construído o espectro de potência de *wavelets* para cada série. As figuras 11a a 19a mostram as séries temporais de precipitação para o período compreendido entre 1974 e 2021. O espectro de potência *wavelets* e informações sobre a potência (valor absoluto)² da transformada para as precipitações diárias são apresentados nas Figuras 11 b a 19 b. Nestas figuras, o eixo x representa a escala temporal em anos e no eixo y os períodos presentes na série, em dias.

Como as séries temporais são finitas, erros ocorrerão no início e no fim do espectro de potência. Uma solução para diminuir a variância foi preencher as séries com zeros o suficiente para levar seu comprimento N até a próxima potência de 2. A região hachurada nas figuras 11b a 19b representa o cone de influência, que se trata da região na qual o efeito de bordas são mais relevantes, os picos nestas regiões foram reduzidos em sua magnitude devido ao preenchimento com zeros, assim a diminuição de potência nestas regiões não acarretam necessariamente uma diminuição da variância. O contorno em negrito indicam áreas com intervalos de significância superior a 95%.

Nas Figuras 11c a 19c são apresentados o Espectro global da *wavelet* (GWS) que

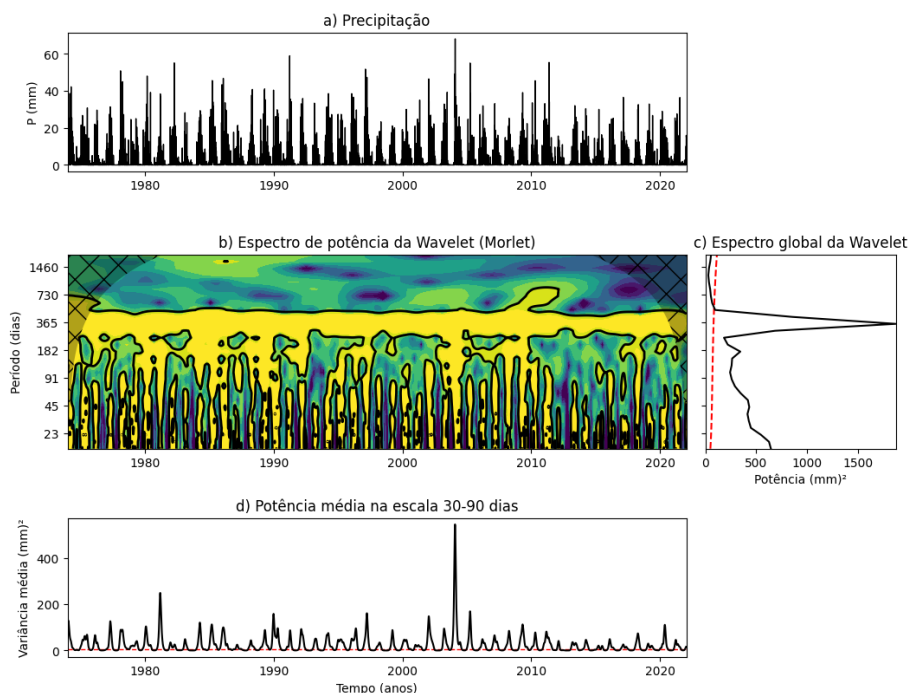
determina o período de maior variabilidade na energia da série. Por fim, as figuras 11d a 19d representam a potência de onda média na escala de tempo entre 30 e 90 dias.

As Figuras 11b a 19b apresentam a distribuição de potência nas diferentes bandas de frequência para as séries de precipitação analisadas. Observa-se que a maior concentração de potência ocorre em regiões com períodos próximos a um ano, o que sugere a presença de uma significativa variabilidade interanual nas séries de precipitações. No entanto, é importante ressaltar que também há uma considerável variabilidade em períodos inferiores a 90 dias, evidenciando a presença de uma variabilidade sub-sazonal nas séries analisadas.

Essa variabilidade sub-sazonal é confirmada pelo Espectro global, uma vez que os picos presentes em bandas de frequência inferiores a 90 dias são significantes em todas as séries. Além disso, é possível constatar que a maioria dos picos de precipitação presentes nas séries analisadas está associada a pulsos de potência significativa na banda de 23 a 91 dias, o que reforça a evidência da presença de variabilidade sub-sazonal nas séries.

Os resultados mencionados anteriormente são corroborados pelas Figuras 11d a 19d, que fornecem uma medida da variação média sub-sazonal em relação ao tempo. Os picos retratam os anos em que ocorreram as maiores variações de precipitação na faixa de 30 a 90 dias, evidenciando uma variabilidade sub-sazonal consistente em todas as séries.

Figura 11 – (a) Hietograma da bacia do Banabuiú. (b) Espectro de potência *wavelet*. (c) Espectro de potência global (d) Potência de onda média na escala de faixa de 30-90 dias.



Fonte: Elaborado pelo Autor, 2023

Figura 12 – Mesmo que a Figura 11, mas para bacia do Orós

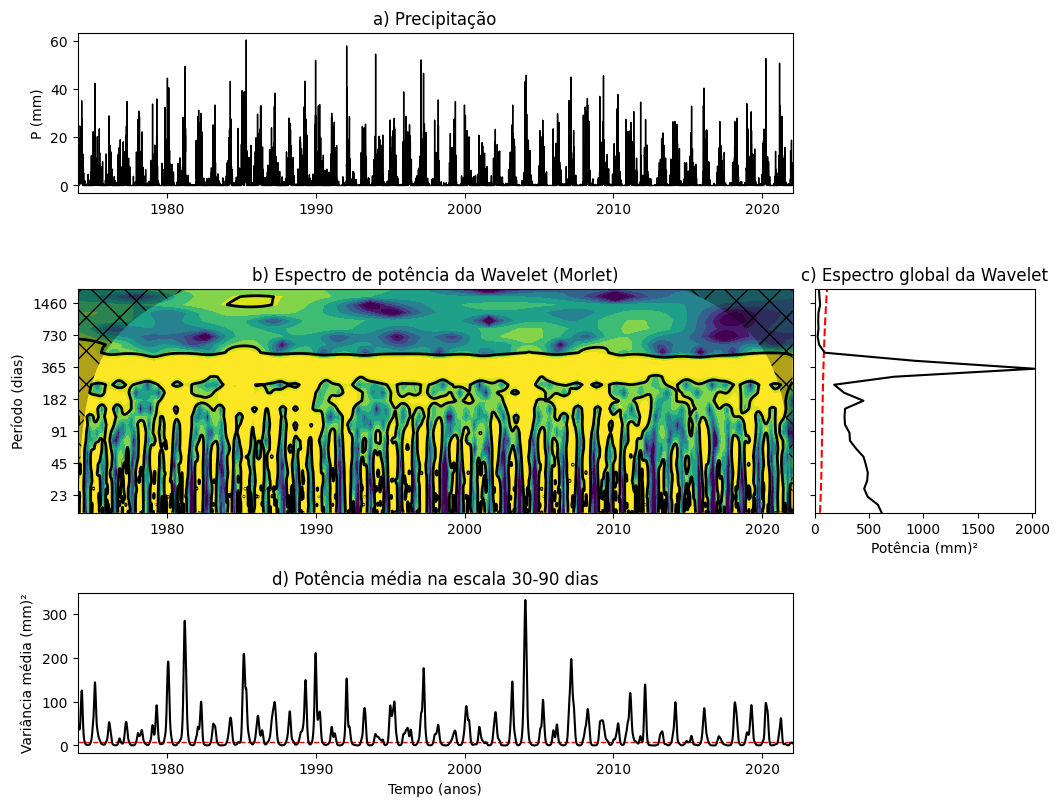


Figura 13 – Mesmo que a Figura 11, mas para bacia do Castanhão

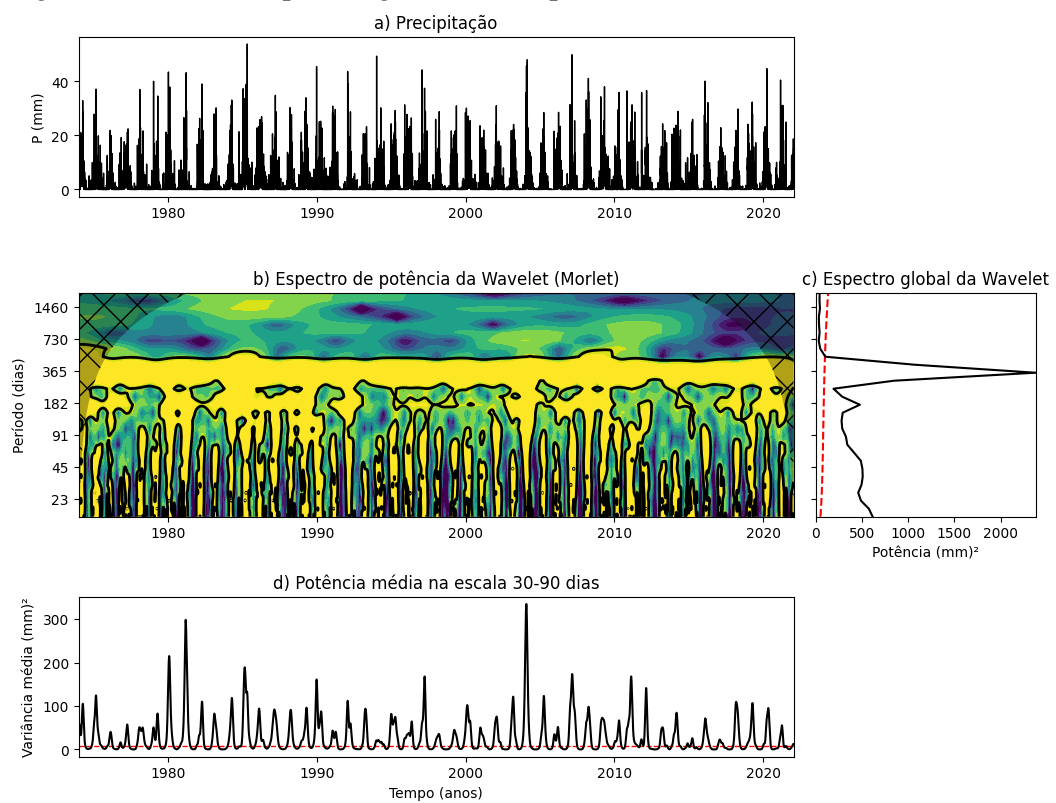
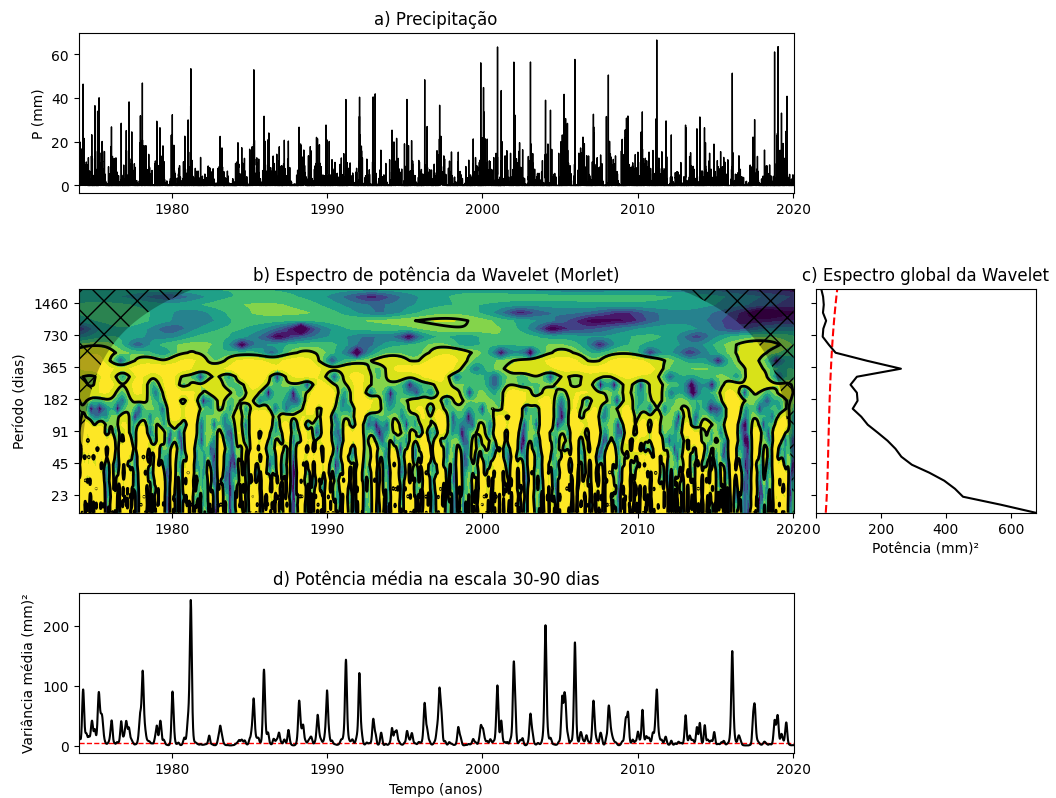
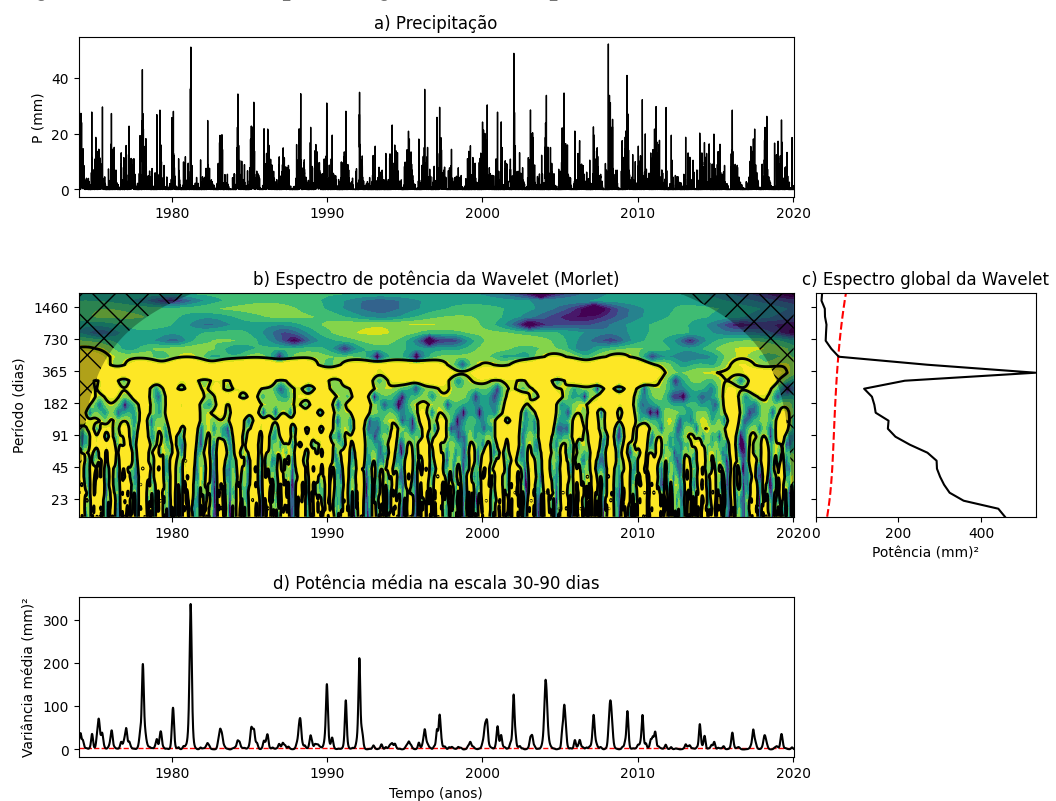


Figura 14 – Mesmo que a Figura 11, mas para bacia do Xingó.



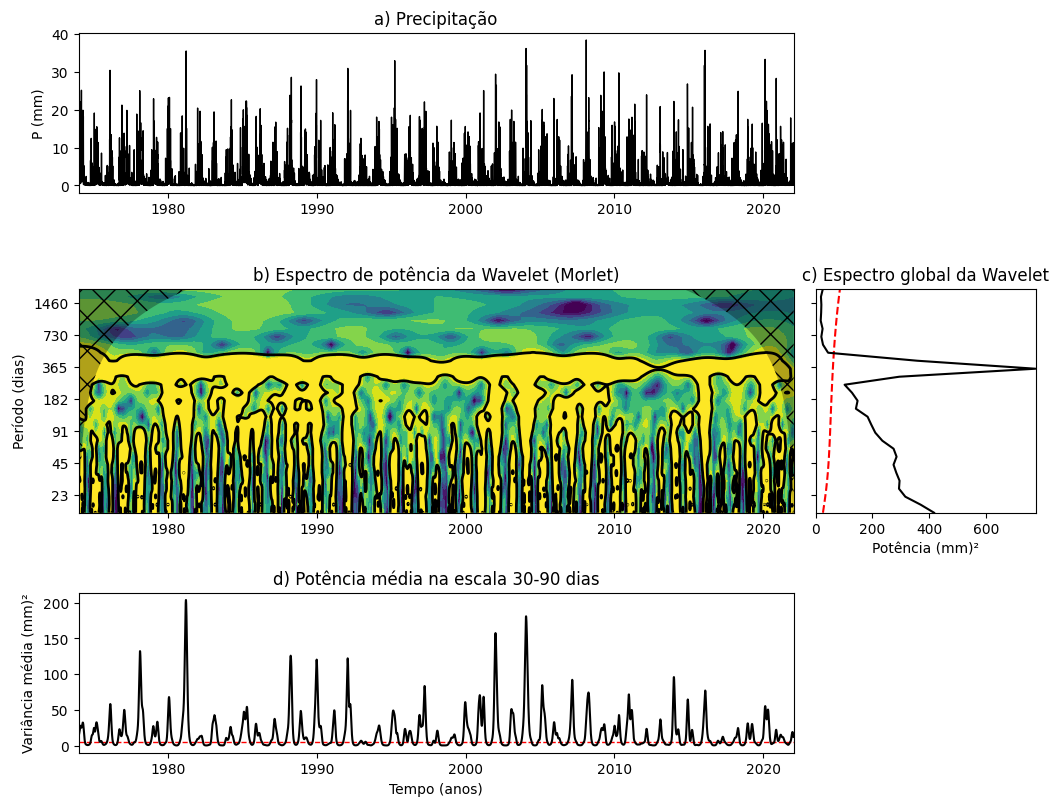
Fonte: Elaborado pelo Autor, 2023

Figura 15 – Mesmo que a Figura 11, mas para bacia de Paulo Afonso



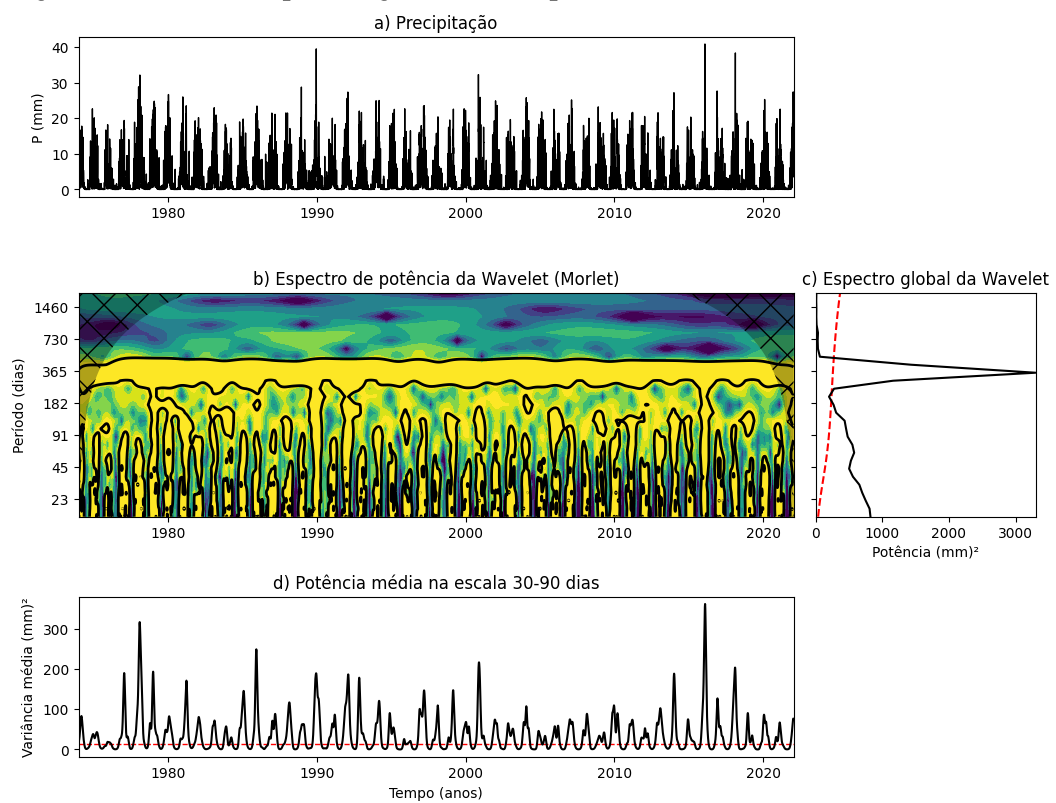
Fonte: Elaborado pelo Autor, 2023

Figura 16 – Mesmo que a Figura 11, mas para bacia de Luiz Gonzaga



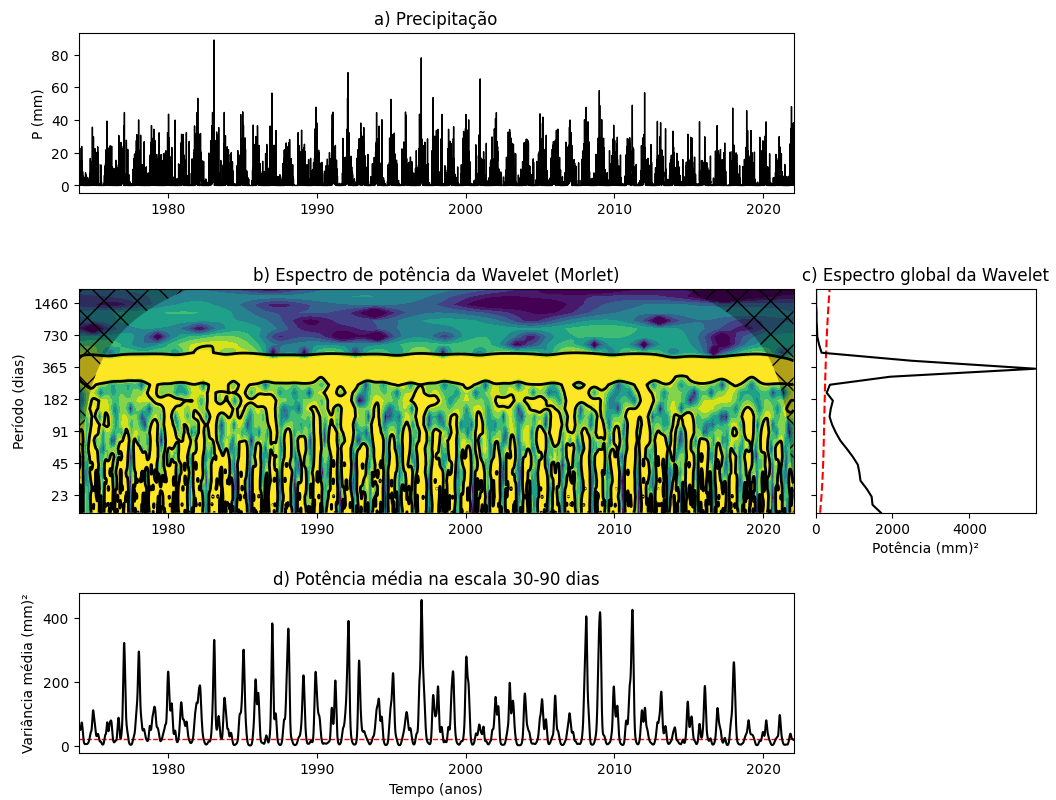
Fonte: Elaborado pelo Autor, 2023

Figura 17 – Mesmo que a Figura 11, mas para bacia de Sobradinho



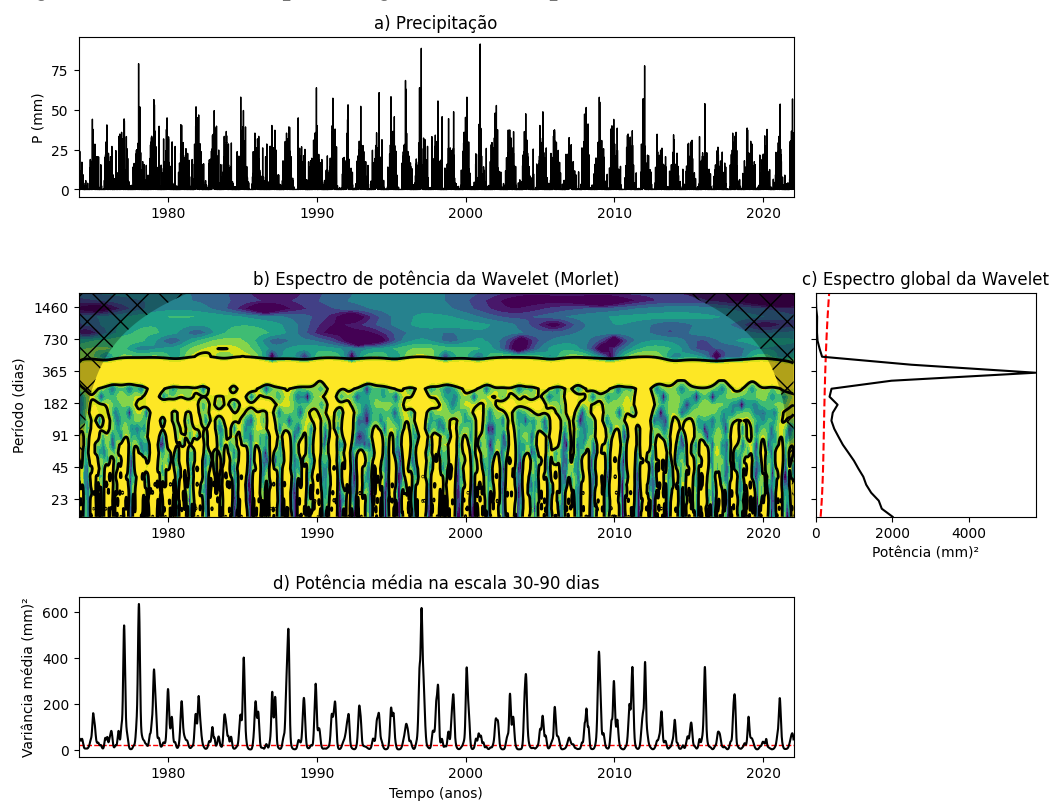
Fonte: Elaborado pelo Autor, 2023

Figura 18 – Mesmo que a Figura 11, mas para bacia de Três Marias



Fonte: Elaborado pelo Autor, 2023

Figura 19 – Mesmo que a Figura 11, mas para bacia de Retiro Baixo



Fonte: Elaborado pelo Autor, 2023

A variabilidade intrassazonal das precipitações na região de estudo é um fenômeno de extrema importância e complexidade, impactando diretamente a distribuição espacial e temporal das chuvas dentro de uma estação chuvosa. Essas flutuações de curta duração e alta frequência desempenham um papel fundamental na gestão dos recursos hídricos. Compreender como os diferentes modos atmosféricos influenciam essa variabilidade e a ocorrência de eventos extremos é crucial para desenvolver estratégias eficazes de manejo hídrico na região.

2.6.2 Análise da influência dos Modos de Variabilidade

Conforme discutido no Tópico 2.3, a OMJ é um modo de variabilidade climática intrassazonal com um período de 30 a 60 dias. Esse fenômeno tem impactos significativos nas anomalias de precipitação e nos eventos extremos em escala global. Compreender os efeitos da OMJ é crucial para entender a modulação das atividades convectiva nas bacias estudadas.

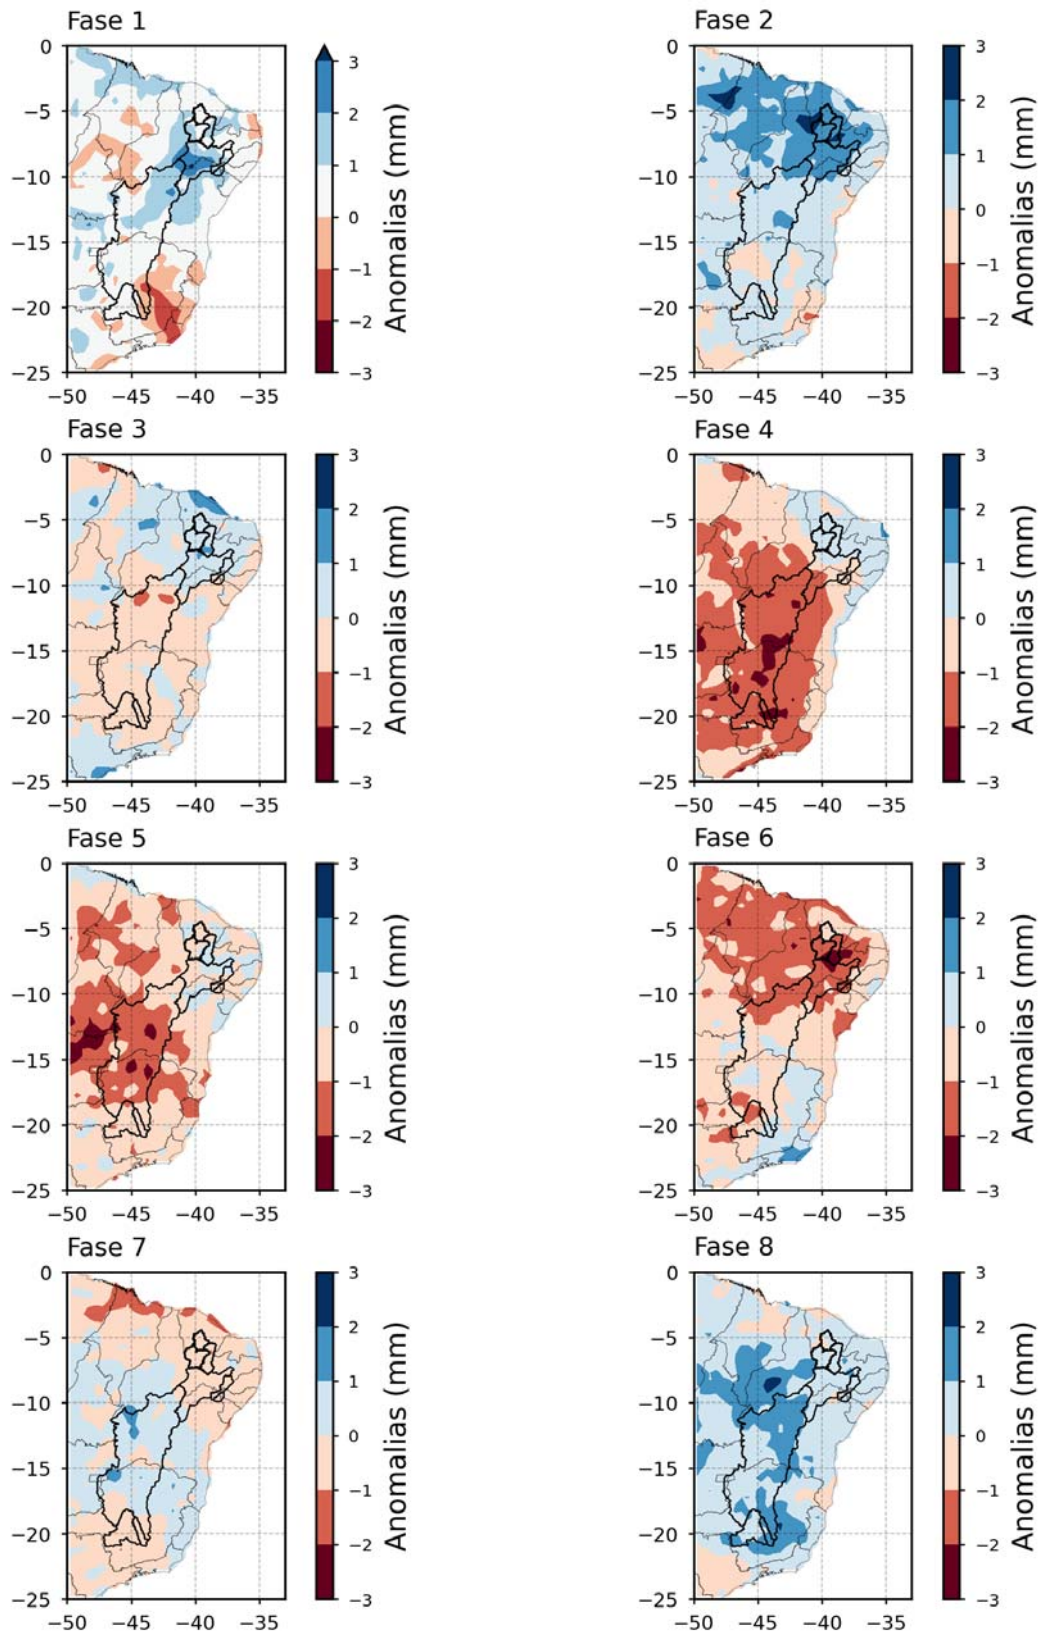
A Figura 20 apresenta as anomalias diárias de precipitação, em períodos cuja amplitude da oscilação foi maior que um (fase ativa da OMJ), para os meses de dezembro a maio. Observa-se que nas bacias de Retiro Baixo, Três Marias e Sobradinho, as anomalias negativas são mais pronunciadas durante as fases 4 e 5 da OMJ. Por outro lado, nas bacias do Luiz Gonzaga, Paulo Afonso, Xingó e nas bacias do Jaguaribe, as anomalias negativas são mais significativas durante a fase 6 da OMJ.

As bacias estudadas também apresentaram variações nas anomalias positivas de precipitação de acordo com as diferentes fases da oscilação. Verificou-se que a fase 8 favoreceu a ocorrência de precipitações em praticamente todas as bacias. Além disso, nas bacias cearenses, bem como nas bacias de Luiz Gonzaga, Paulo Afonso e Xingó, foram observadas fortes anomalias positivas durante a fase 2 da oscilação. Embora as anomalias mais evidentes tenham sido registradas na fase 2, também foi constatada a presença de anomalias positivas, porém de menor intensidade, nas fases 1, 3 e 4 dessas mesmas bacias.

A Figura 21 apresenta as anomalias diárias de precipitação durante a fase inativa da OMJ. Em contraste com a Figura 20 que retrata a fase ativa, na fase inativa observa-se uma inversão nas anomalias em comparação com a fase ativa. As áreas previamente afetadas por déficits de chuva mostram uma atenuação das condições de estiagem, principalmente nas fases 1, 4 e 6 da OMJ. Por outro lado, regiões que inicialmente apresentaram condições favoráveis à precipitação tornam-se menos propícias durante a fase inativa, como nas fases 1, 2 e 8.

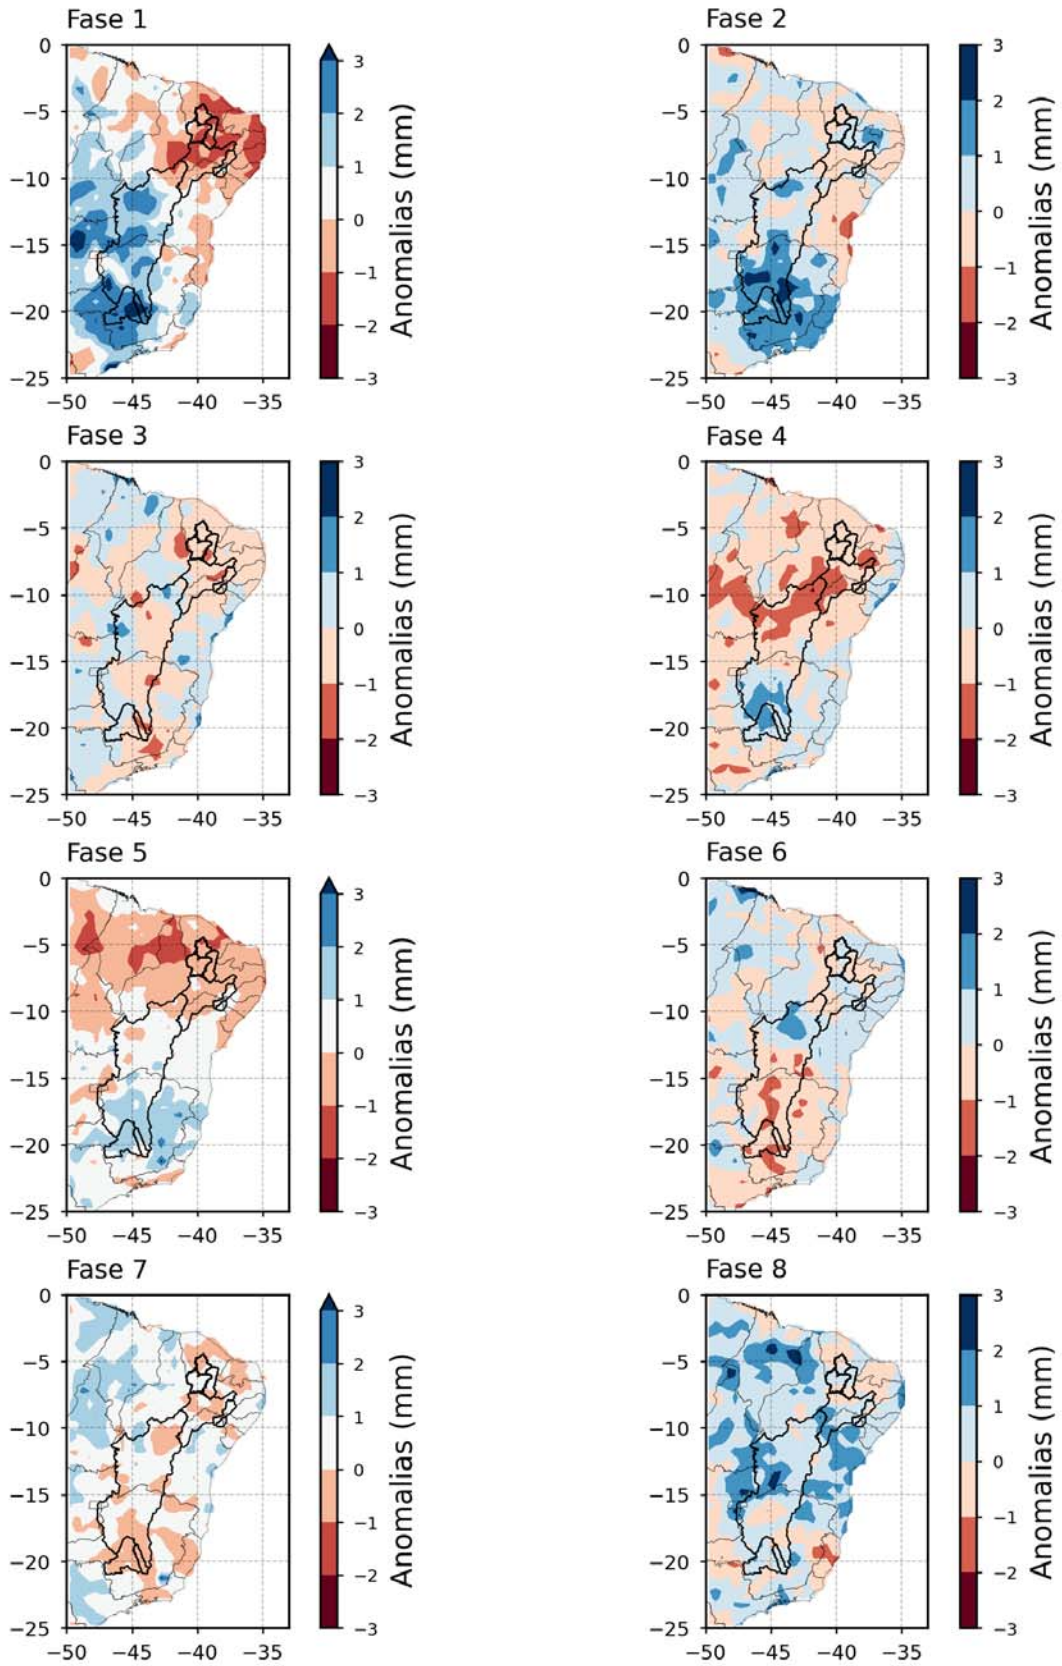
Conforme discutido no Tópico 2.3, o fenômeno ENOS é reconhecido como uma

Figura 20 – Anomalias da precipitação média (mm dia^{-1}) para as diferentes fases da OMJ (Fase ativa).



Fonte: Elaborado pelo Autor, 2023

Figura 21 – Mesmo que a Figura 20, mas para fase inativa



Fonte: Elaborado pelo Autor, 2023

das principais fontes de variabilidade climática interanual. A interação entre a OMJ e o ENOS tem sido objeto de estudos para entender melhor os efeitos combinados desses dois fenômenos na variabilidade das precipitações. Buscando evidenciar os efeitos e a influência da OMJ na variabilidade intrassazonal das precipitações, a Figura 22 apresenta a proporção de eventos de chuvas extremas para as distintas fases da OMJ durante períodos em que o ENOS foi classificado como neutro. Adicionalmente, nas Figuras 23 e 24, são expostas as proporções em anos caracterizados pela ocorrência de El Niño e La Niña, respectivamente.

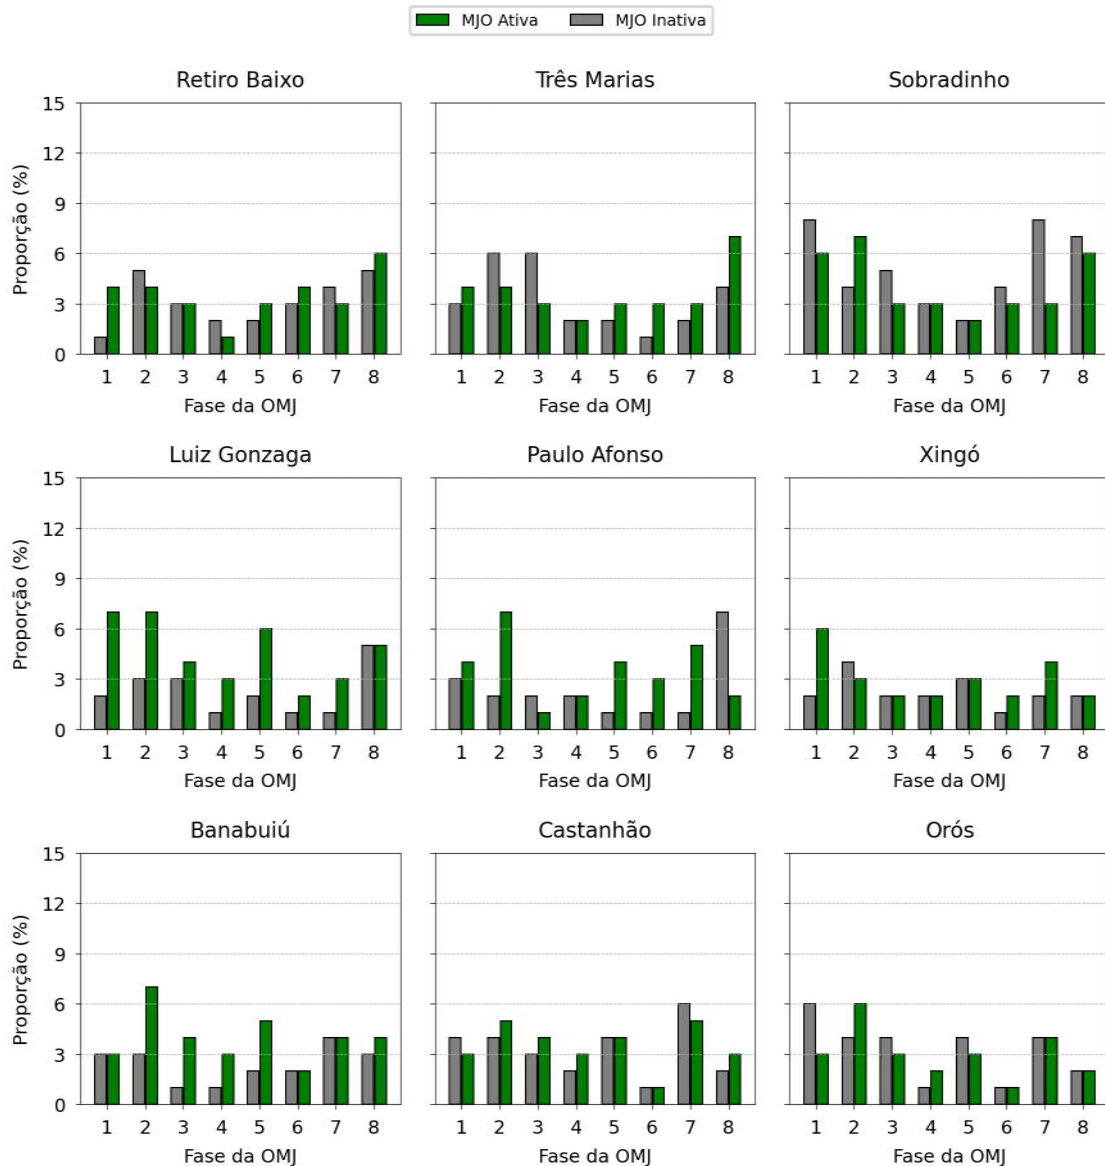
A Figura 22 revela características distintas da influência da OMJ, independentemente dos efeitos diretos do ENOS. Durante a fase ativa da OMJ, é possível observar uma maior proporção de eventos de chuvas extremas nas bacias de Retiro Baixo, Três Marias e Sobradinho na fase 8, nas bacias de Luiz Gonzaga e Paulo Afonso nas fases 1, 2 e 5, e nas bacias de Banabuiú, Castanhão e Orós na fase 2. Os resultados obtidos estão em concordância com pesquisas anteriores que investigaram a influência da OMJ nas anomalias diárias de precipitação no Nordeste do Brasil NEB. Valadão *et al.* (2017) encontraram anomalias de precipitação no NEB durante o verão austral. Seus resultados indicaram que aproximadamente 80% das estações pluviométricas apresentaram aumento de precipitação nas fases 1-2 da OMJ.

Os resultados obtidos por Monteiro¹ (2022) também revelam anomalias significativas de precipitação durante o período da pré-estação chuvosa e o período chuvoso no semiárido nordestino durante as fases da OMJ. Os resultados destacam especificamente as fases 2, 8 e 1 da OMJ como períodos em que ocorrem uma maior incidência de chuvas na região.

Ainda segundo Monteiro¹ (2022), a influência da direção de propagação e das fases da OMJ na ocorrência de precipitação na região é especialmente relevante durante o período entre novembro e março. Durante sua propagação, a OMJ tem a capacidade de interagir com outros sistemas meteorológicos que afetam a região, tais como frentes frias, áreas de baixa pressão e sistemas convectivos. Essa interação pode desencadear condições favoráveis para a ocorrência de precipitação significativa na região, ao mesmo tempo em que pode inibir a formação de chuvas.

Em períodos de ocorrência de eventos de El Niño e La Niña, os padrões de anomalias observados durante o ENOS sem a presença da OMJ podem ser amplificados quando o ENOS e a OMJ ocorrem simultaneamente. Na região estudada, foi observado que, durante períodos de El Niño (Figura 23), a OMJ principalmente nas fases 1 e 2, tendem a modular os efeitos históricos do El Niño. Em bacias como Retiro Baixo, Três Marias e Sobradinho, a presença da OMJ nas fases 1 e 2 resultou em uma diminuição na ocorrência de eventos extremos. Por outro lado, nas

Figura 22 – Proporção de chuvas extremas: OMJ coincidindo com ENOS neutro.

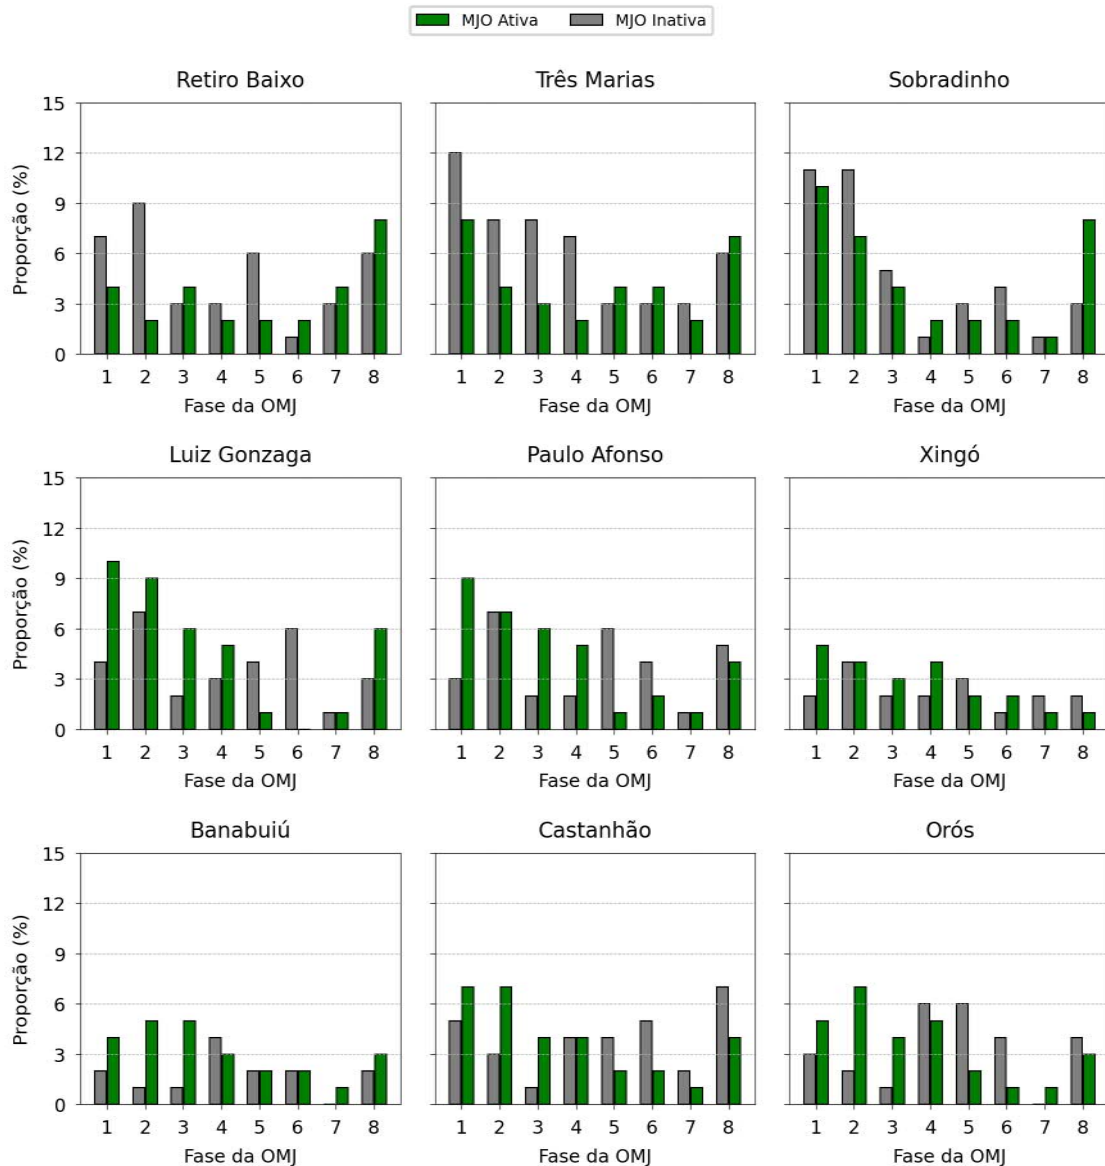


Fonte: Elaborado pelo Autor, 2023

demais bacias, a presença da OMJ nas fases 1 e 2 contribuiu para um aumento na proporção de chuvas extremas.

Quando ocorre a associação da OMJ com eventos de La Niña (Figura 24), é possível observar padrões específicos nas precipitações extremas nas bacias analisadas. Durante a fase ativa da OMJ, verifica-se uma redução das chuvas consideradas extremas nas bacias de Retiro Baixo, Três Marias e Sobradinho quando a oscilação está nas fases 4 e 5. Nas bacias de Paulo Afonso e Luiz Gonzaga, o mesmo padrão é observado, mas com maior impacto nas fases 6 e 7 da OMJ. Já na bacia de Banabuiú, é notável uma diminuição na proporção de chuvas extremas quando a OMJ está na fase 2.

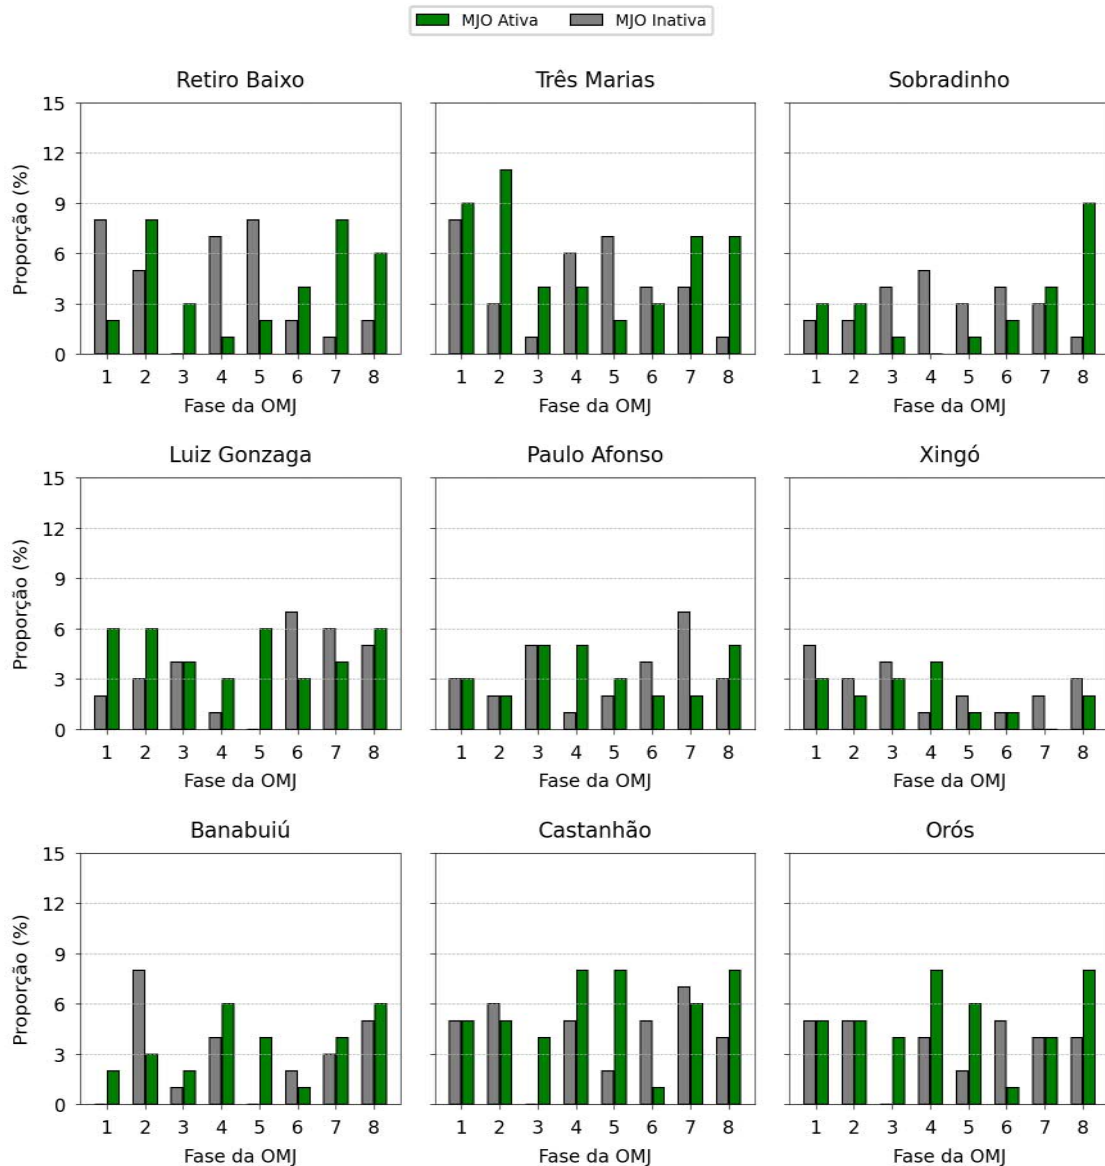
Figura 23 – Proporção de chuvas extremas: OMJ coincidindo com El Niño.



Fonte: Elaborado pelo Autor, 2023

O relacionamento entre as fases do ENOS e OMJ ainda é objeto de estudo e há diferentes perspectivas sobre como esses fenômenos interagem. No entanto, é importante ressaltar que a relação entre esses fenômenos, conforme observado, não é totalmente linear. Há eventos de El Niño em que a OMJ não é afetada de forma significativa, e em outros casos, a OMJ pode até mesmo se intensificar. É necessário considerar que tanto a OMJ e o ENOS são fenômenos complexos e influenciados por múltiplos fatores. A relação entre esses fenômenos ainda é objeto de pesquisa e há variações nos resultados obtidos. Portanto, trata-se de um campo de estudo em constante evolução, e mais pesquisas são necessárias para compreender melhor a sua interação.

Figura 24 – Proporção de chuvas extremas: OMJ coincidindo com La Niña.



Fonte: Elaborado pelo Autor, 2023

2.7 Conclusões

O presente capítulo teve como objetivo analisar a variabilidade temporal e espacial das precipitações em diversas bacias hidrográficas em escala sub-sazonal. Os resultados revelaram a existência de flutuações de curta duração e alta frequência dentro de uma estação chuvosa, evidenciando uma variabilidade sub-sazonal consistente em todas as séries de dados analisadas. Isso ressalta a importância de considerar essas variações intrassazonais na compreensão da distribuição espacial e temporal das chuvas nessas regiões.

Além disso, a Oscilação Madden-Julian OMJ demonstrou ter uma influência significativa na variabilidade das precipitações. Durante a fase ativa da OMJ, observou-se que a fase 8 favoreceu a ocorrência de precipitações em praticamente todas as bacias. Também foi possível observar anomalias positivas significativas na fase 2 da OMJ. Por outro lado, nas bacias de Retiro Baixo, Três Marias e Sobradinho, as fases 4 e 5 apresentaram anomalias negativas mais pronunciadas, e nas bacias do Luiz Gonzaga, Paulo Afonso, Xingó e Jaguaribe, foram registradas anomalias negativas significativas durante a fase 6.

Além disso, a interação entre o fenômeno El Niño-Oscilação Sul ENOS e a OMJ revelou-se relevante nas diferentes fases da OMJ. Durante os eventos de El Niño, a presença da OMJ, principalmente nas fases 1 e 2, exerceu modulações nos efeitos históricos desse fenômeno. Essa interação resultou em uma diminuição na ocorrência de eventos extremos de chuva em algumas bacias e um aumento na proporção de chuvas extremas em outras.

A compreensão da variabilidade sub-sazonal das precipitações e da interação dos diferentes modos de variabilidade que atuam na região, desempenham um papel crucial na gestão dos recursos hídricos no contexto do semiárido brasileiro. Essa região é conhecida por sua variabilidade climática e pela ocorrência de longos períodos de estiagem, caracterizados pelos veranicos, que afetam significativamente a disponibilidade de água.

A gestão adequada dos recursos hídricos é fundamental para garantir a segurança hídrica da população, da produção agrícola e a conservação dos ecossistemas. Ao compreender a variabilidade sub-sazonal e a influência conjunta dos diferentes fenômenos atmosféricos, é possível desenvolver estratégias adaptáveis e resilientes, promovendo uma melhor gestão dos recursos hídricos e aumentando a resiliência da região às condições climáticas variáveis.

3 AVALIAÇÃO DA PERFORMANCE DE MODELOS NUMÉRICOS PARA PREVISÃO SUB-SAZONAL DE PRECIPITAÇÃO

3.1 Introdução

Os modelos numéricos de previsão de variáveis meteorológicas foram desenvolvidos com o objetivo de estimar comportamentos futuros do clima, tomando por base o acoplamento oceano-atmosfera. Os modelos numéricos são ferramentas utilizadas para minimizar os impactos causados pelas incertezas climáticas, principalmente em regiões vulneráveis aos impactos causados pelas mudanças climáticas, como é o caso do Nordeste do Brasil.

O ponto de partida dos modelos numéricos de previsão é o trabalho de Bjerknes (1904) ao demonstrar que o estado futuro da atmosfera poderia ser descrito pela integração de equações diferenciais que governam o comportamento da atmosfera. Entretanto, foi o cientista britânico Lewis Fry Richardson que, em 1913, realizou a primeira integração numérica compreensível destas equações para calcular as mudanças na pressão atmosférica e nos ventos em dois pontos na Europa Central.

Mesmo sem cometer erros grosseiros de cálculos, os resultados encontrados por Richardson foram considerados ruins e não realísticos. Somente nos anos 30 é que os matemáticos identificaram problemas com o método numérico usado por Richardson e questões de equilíbrio entre o campo da pressão e do vento nas condições iniciais do modelo predictor, o que prejudicou suas análises (SAMPAIO; DIAS, 2014).

Com a evolução dos computadores, o aprimoramento e melhoria na compreensão dos principais processos físicos de pequena escala (nuvens, precipitações, transferência turbulenta de calor, umidade, momento e radiação) e a utilização de métodos mais precisos na obtenção de dados a habilidade de previsão dos modelos numéricos apresentaram melhorias significantes (KALNAY, 2003).

Uma das principais ferramentas utilizadas para previsões climáticas são os modelos numéricos, conhecidos como Modelos Numéricos de Circulação Geral (MCG). Esses modelos são compostos por um conjunto de equações matemáticas que descrevem situações físicas complexas. A metodologia numérica adotada discretiza essas equações em sistemas de equações lineares, que são então resolvidas com o auxílio de computadores, dentro de uma certa tolerância (YNOUE *et al.*, 2017).

Os MCG são usados para prever uma ampla gama de variáveis climáticas, incluindo

temperatura, umidade, pressão atmosférica, ventos e precipitação. Eles são construídos com base em uma vasta gama de dados observacionais, que incluem registros históricos de observações climáticas, bem como dados de satélite e de estações meteorológicas em todo o mundo. Esses dados são usados para ajustar e validar os modelos, garantindo que suas previsões sejam confiáveis.

As previsões são definidas de acordo com seu tempo máximo de antecedência futura: curto, médio e longo prazo. As previsões de curto prazo (horárias ou diárias), utilizam horizontes de previsibilidade de até duas semanas e normalmente são classificadas como previsão de tempo. As previsões de longo prazo (sazonal), utilizam horizontes mais longos, normalmente variando de três a seis meses, são frequentemente utilizadas para propósitos de planejamento e operação de recursos hídricos. Já as previsões sub-sazonais compreendem períodos intermediários entre as previsões de curto prazo e as sazonais, normalmente variando de duas semanas a dois meses.

Apesar da crescente demanda para preencher as lacuna existentes entre as previsões de curto prazo e as previsões de longo prazo, as previsões sub-sazonais ainda são consideradas difíceis de serem realizadas, devido ao seu período intermediário, que, em termos de previsões meteorológicas, é relativamente longo, resultando na perda da maioria das condições iniciais do tempo. Ao mesmo tempo, em relação às previsões climáticas, esse período é considerado curto para ser significativamente influenciado pela variabilidade oceânica (VITART; ROBERTSON, 2018).

Ao longo das últimas décadas, vários estudos têm sido conduzidos para desenvolver modelos numéricos e técnicas de análise capazes de melhorar a previsão sub-sazonal. No entanto, ainda há muitas questões em aberto, como a melhor forma de incluir a variabilidade intrínseca do sistema climático nos modelos, a melhor forma de integrar dados observacionais e modelagem numérica e a melhor forma de comunicar as incertezas associadas às previsões sub-sazonais.

Este capítulo tem por objetivo apresentar uma análise da eficiência de modelos de previsão sub-sazonal de precipitação nas bacias hidrográficas do rio São Francisco e do rio Jaguaribe, a fim de fornecer subsídios para aprimorar o uso dessas ferramentas em diferentes setores. Os modelos em questão são o *Brazilian Global Atmospheric Model* (BAM) desenvolvido pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), o *Climate Forecast System Version 2* (CFSv2) e o *Global Ensemble Forecast System Version 2* (GEFSv2), ambos desenvolvidos pelo National Centers for Environmental Prediction (NCEP), e o *Earth System Research Laboratory* (ESRL), desenvolvido pelo *National Oceanic and Atmospheric Administration* (NOAA).

3.2 Modelos matemáticos

As equações fundamentais que descrevem os fenômenos climáticos são baseadas na conservação do momento linear e na conservação de massa. Essas equações podem ser expressas de duas maneiras: através de balanços de massa ou momento em um volume de controle fixo no espaço - conhecido como referencial Euleriano - ou em modelos em que o volume se move com a parcela de fluido, conhecido como referencial Lagrangeano.

As equações apresentadas neste tópico são abordados do ponto de vista Euleriano, que é um referencial fixo no espaço. Nesse referencial, a quantidade de massa e momento dentro do volume de controle é constante e a conservação é expressa em termos de fluxos de entrada e saída. Esse modelo é comumente usado na modelagem do clima e da atmosfera, permitindo o estudo de fenômenos em diferentes escalas de tempo e espaço.

As principais equações que descrevem os processos fundamentais que ocorrem na atmosfera são listadas a seguir. Mais detalhes sobre tais equações podem ser encontrados em (KALNAY, 2003; HALTINER; WILLIAMS, 1980; JAMES, 1995).

Segunda lei de Newton ou Conservação do momento linear:

Para estudar os fenômenos atmosféricos, é comum utilizar um referencial não-inercial, como aquele que está em rotação com origem centrada no centro da Terra. Nesse tipo de referencial, é necessário levar em conta as forças inerciais que atuam sobre um sistema. Por isso, a segunda lei de Newton deve ser modificada para incluir essas forças. Desse modo, as forças por unidade de massa que agem em uma parcela de fluido confinada em volume de controle podem ser expressas como:

$$\frac{\partial \vec{V}}{\partial t} + \vec{V} \cdot \nabla \vec{V} = -\frac{\nabla p}{\rho} + \nabla \phi - 2\vec{\Omega} \times \vec{V} + \vec{F}_v \quad (3.1)$$

onde \vec{V} é a velocidade relativa do fluido, $\vec{V} \cdot \nabla \vec{V}$ é o termo de advecção, ρ é a densidade, ∇p é a força por unidade de massa devido ao gradiente de pressão, $\nabla \phi$ é a gravidade aparente - onde ϕ é a função escalar geopotencial, $2\vec{\Omega} \times \vec{V}$ é a força de Coriolis - em que $\vec{\Omega}$ é o vetor velocidade angular e \vec{F}_v são forças de fricção.

Equação da continuidade ou conservação da massa:

A equação da continuidade para um volume de controle fixo no espaço pode ser escrita como:

$$\frac{\partial \rho}{\partial t} + \vec{\nabla} \cdot (\rho \vec{V}) = 0 \quad (3.2)$$

onde ρ é a densidade e \vec{V} é a velocidade do fluido. Essa equação afirma que a taxa de variação da densidade no tempo é igual à taxa de variação do fluxo de massa através da superfície do volume de controle. Se o fluxo de massa para dentro do volume de controle for maior que o fluxo de massa para fora, a densidade aumentará e vice-versa. Essa equação é uma consequência da lei de conservação da massa.

Equação de estado dos gases perfeitos:

Os gases atmosféricos são frequentemente tratados como gases perfeitos, para os quais a pressão, p , densidade, ρ , e a temperatura, T , são relacionados pela equação de estado dos gases perfeitos:

$$p = \rho RT \quad (3.3)$$

onde R é a constante universal dos gases.

Primeira lei da Termodinâmica ou conservação da energia

A equação que descreve a conservação da energia em um volume de controle é dada por:

$$C_p \left(\frac{\partial T}{\partial t} + \vec{V} \cdot \vec{\nabla} T \right) = \frac{1}{\rho} \frac{dp}{dt} + Q + F_T \quad (3.4)$$

onde C_p é o calor específico a pressão constante, $\frac{\partial T}{\partial t}$ representa a variação temporal, t , da temperatura, T , no volume de controle, $\vec{V} \cdot \vec{\nabla} T$ representa a variação espacial da temperatura no volume de controle em direção à velocidade do fluido, $\frac{1}{\rho} \frac{dp}{dt}$ representa a variação temporal da pressão no volume de controle e F_T é o trabalho externo por unidade de massa.

Equação da conservação da razão de mistura do vapor de água em um volume de ar

A equação de conservação da razão de mistura do vapor de água em um volume de ar pode ser escrita como:

$$\frac{\partial}{\partial t}(\rho_w q_w) + \nabla \cdot (\rho_w q_w \vec{V}) = \rho_w E - \nabla \cdot \vec{F}_w \quad (3.5)$$

onde ρ_w é a densidade do vapor de água, q_w é a razão de mistura do vapor de água, \vec{V} é a velocidade do ar, E é a taxa de produção de vapor de água por unidade de volume, e \vec{F}_w é o fluxo de vapor de água através da superfície do volume de controle.

A superfície do planeta é dividida em latitudes e longitudes, a intersecção de tais pontos são chamadas de pontos de grade. A distância entre dois pontos de grade fornece a resolução horizontal do modelo. Já a resolução vertical é dada pela divisão dos níveis verticais da atmosfera. Em cada um dos variados níveis as equações nos modelos numéricos são resolvidas e discretizadas no tempo fornecendo estimativas, para um determinado intervalo de tempo, de temperatura, pressão, umidade, componentes do vento etc (KALNAY, 2003).

Verifica-se que a precisão de um modelo é diretamente influenciada pela resolução espacial, no entanto aumentar a resolução espacial representa também um aumento nos custos computacionais, o que torna o processamento mais lento. Os modelos que simulam as condições atmosféricas de todo o planeta são denominados modelos globais. Tais modelos possuem pontos de grade com resolução horizontal em torno de 200 km, aproximadamente 28 níveis verticais e são inicializados com informações de todo o globo terrestre. Esses modelos são ideias para simular características da atmosfera em grande escala (YNOUE *et al.*, 2017).

Para obtenção de informações mais detalhadas da atmosfera, usa-se modelos com maior resolução horizontal, em torno de 20 km, denominados modelos regionais. Os modelos regionais são utilizados para simular as condições atmosféricas em pequenas porções do planeta e representam melhor os fenômenos regionais. Tais modelos, além das condições iniciais, precisam de condições de fronteiras laterais para serem inicializados (YNOUE *et al.*, 2017).

3.3 Metodologia

As previsões sub-sazonais analisadas neste estudo são fornecidas pelos modelos CPTEC, CFSv2, GEFSv2 e ESRL para o período compreendido entre os anos de 1999 a 2016 nas bacias do Orós, Banabuiú, Castanhão, Xingó, Luis Gonzaga, Paulo Afonso, Sobradinho,

Três Marias e Retiro Baixo. A seguir, é apresentada uma breve descrição desses modelos.

3.3.1 Modelos Analisados

O Modelo Numérico BAM versão 2, desenvolvido pelo CPTEC, é destaca-se por suas parametrizações dinâmicas e físicas. O modelo emprega um esquema de advecção Euleriana com transporte de umidade semi-Lagrangiano. Suas características incluem microfísica, modelo de superfície, esquemas de radiação de ondas longas e curtas, e esquemas de camada limite planetária e convecção profunda. A resolução horizontal é de 1,0° de latitude e longitude. Quanto à resolução vertical, o modelo explora duas opções: 42 e 64 níveis verticais. Uma descrição mais abrangente sobre o BAM pode ser encontrada em (GUIMARÃES *et al.*, 2020).

O *Climate Forecast System Version 2* (CFSv2) é um modelo numérico de previsão climática desenvolvido pelo Centro Nacional de Previsão Ambiental (NCEP) dos Estados Unidos. O CFSv2 é uma atualização do modelo anterior, CFS, desenvolvido em 2004. O modelo CFSv2 utiliza um sistema avançado de assimilação de dados que integra observações meteorológicas e oceanográficas em seu modelo, aumentando significativamente a precisão das previsões.

Com resolução horizontal de 0,25 graus (cerca de 28 km) e 64 níveis verticais, o CFSv2 é capaz de prever diversas variáveis climáticas, incluindo temperatura do ar, precipitação, umidade relativa, ventos, pressão atmosférica, temperatura da superfície do mar e anomalias de temperatura da superfície do mar. Além disso, o modelo fornece previsões de precipitação para horizontes de até 44 dias, com quatro membros distintos (condições iniciais). Mais detalhes sobre este modelo podem ser encontrados em Saha *et al.* (2014)

O *Global Ensemble Forecast System Version 2* (GEFSv2) é um modelo numérico de previsão do tempo global, também desenvolvido pelo NCEP. O modelo é executado uma vez por semana e consiste em 11 membros, cada um representando uma versão do modelo com diferentes condições iniciais e físicas. Ele tem uma resolução horizontal de cerca de 35 km e pode prever uma variedade de variáveis meteorológicas, incluindo temperatura, precipitação, vento, umidade relativa e pressão atmosférica, com previsões de até 35 dias.

As previsões do GEFSv2 são geradas por meio de processos, que utiliza observações de satélites, estações meteorológicas e outros meios para inicializar o modelo e melhorar sua precisão. O modelo também utiliza técnicas avançadas de modelagem para simular processos meteorológicos, como a formação de nuvens, a transferência de calor e umidade, e a interação entre a superfície terrestre e a atmosfera. Mais detalhes sobre este modelo podem ser encontrados

em Zhou *et al.* (2017).

Desenvolvido pelo *National Oceanic and Atmospheric Administration (National Oceanic and Atmospheric Administration (NOAA))*, o modelo aqui referido como ESRL trata-se de um modelo numérico acoplado de previsão do tempo para escalas de tempo sub-sazonais. O modelo consiste em uma versão de grade icosaédrica do Modelo Icosaédrico de Seguimento de Fluxo Hidrostático Atmosférico (FIM) acoplada ao Modelo Híbrido de Coordenadas do Oceano (iHYCOM).

Todas as componentes do ESRL (atmosfera, superfície terrestre, oceano e gelo marinho) são inicializados a partir da Reanálise do CFS e das análises operacionais CFSv2. O modelo realiza previsões contendo quatro membros, para horizontes de até quatro semanas. A resolução horizontal é de aproximadamente 60 km para FIM e iHYCOM. O FIM possui 64 camadas verticais, enquanto o iHYCOM possui 32. Mais detalhes sobre este modelo podem ser encontrados em Sun *et al.* (2018).

3.3.2 Validação das previsões

Para validar as previsões de precipitação realizadas pelos modelos foi realizada a comparação com os dados de precipitação médias diárias observadas nas bacias do rio São Francisco e nas bacias do Banabuiú, Orós e Castanhão. As precipitações observadas foram obtidas da Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) e da Agência Nacional de Águas (ANA). Os índices estatísticos utilizados nas validações estão listados a seguir.

- **Nash-Sutcliffe Efficiency (NSE):** O índice é amplamente utilizado para avaliar o desempenho de modelos hidrológicos e atmosféricos na previsão de vazão e precipitação. Este índice é uma medida da proporção da variância observada que é explicada pelo modelo e é calculado como a razão entre a soma dos quadrados dos desvios entre as observações e as previsões, e a soma dos quadrados dos desvios entre as observações e a média observada. O valor do índice varia de $-\infty$ a 1, sendo que valores próximos a 1 indicam um bom ajuste do modelo aos dados observados, enquanto valores menores que zero indicam um desempenho pior do que uma simples medição da média dos valores observados (WILKS, 2011).

$$NSE = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2}$$

- **Coefficiente de Correlação de Pearson (r):** Mede o grau de correlação entre as variáveis prevista e observada, podendo variar entre -1 e 1. $r = 1$ indica correlação perfeita e positiva, de modo que os valores da variável analisada são diretamente proporcionais; $r = -1$ indica correlação perfeita e negativa, sendo os valores inversamente proporcionais; e $r = 0$ indica que não há correlação entre os valores (WILKS, 2011).

$$r = \frac{\sum_{t=1}^n (y_t - \bar{y})(\hat{y}_t - \bar{\hat{y}})}{\sqrt{\sum_{t=1}^n (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^n (\hat{y}_t - \bar{\hat{y}})^2}}$$

- **Viés:** Definido como uma medida do desvio sistemático de uma estimativa em relação ao verdadeiro valor do parâmetro que está sendo estimado. Quando o viés é próximo de zero, indica que a variável está sendo bem observada, ou seja, a previsão está próxima do valor observado ou real. Por outro lado, um viés negativo indica que a previsão subestima a variável e um viés positivo indica superestimação (WILKS, 2011).

$$Vies = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - \bar{y})$$

- **Erro Quadrático Médio (MSE):** Trata-se da média de todos os erros quadráticos atrelados a cada valor de previsão. Por elevar as diferenças individuais ao quadrado, o MSE é sempre positivo e mais sensível aos grandes erros. Para uma simulação perfeita o MSE = 0 (WILKS, 2011).

$$MSE = \frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2$$

- **Raiz Quadrada do Erro Médio (RMSE):** É definido como a raiz quadrada da média dos quadrados dos desvios entre os valores previstos e os valores observados. (WILKS, 2011).

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}}$$

Em que y representa a precipitação observada, \hat{y} a precipitação prevista, \bar{y} a média da precipitação observada, $\hat{\bar{y}}$ a média da precipitação estimada, t o período e n o número de amostras.

Como os modelos apresentam distintas condições iniciais (número de membros), diferentes previsões são geradas. Desta forma, foi adotado o método de *ensemble* médio dos modelos, que consiste em calcular a média das múltiplas simulações obtidas a partir de modificações nas condições iniciais de cada modelo.

As avaliações foram centradas nas precipitações acumuladas em horizontes de 7, 14, 21, 28, 35 e 42 dias, para os meses de Novembro a Julho, visto que esse período engloba os meses em que são observados os maiores índices de precipitação nas bacias, ou seja, janeiro a maio para as bacias do Castanhão, Orós, Banabuiú, Luiz Gonzaga e Paulo Afonso, e de novembro a março para as bacias de Sobradinho, Três Marias e Retiro Baixo.

3.4 Resultados

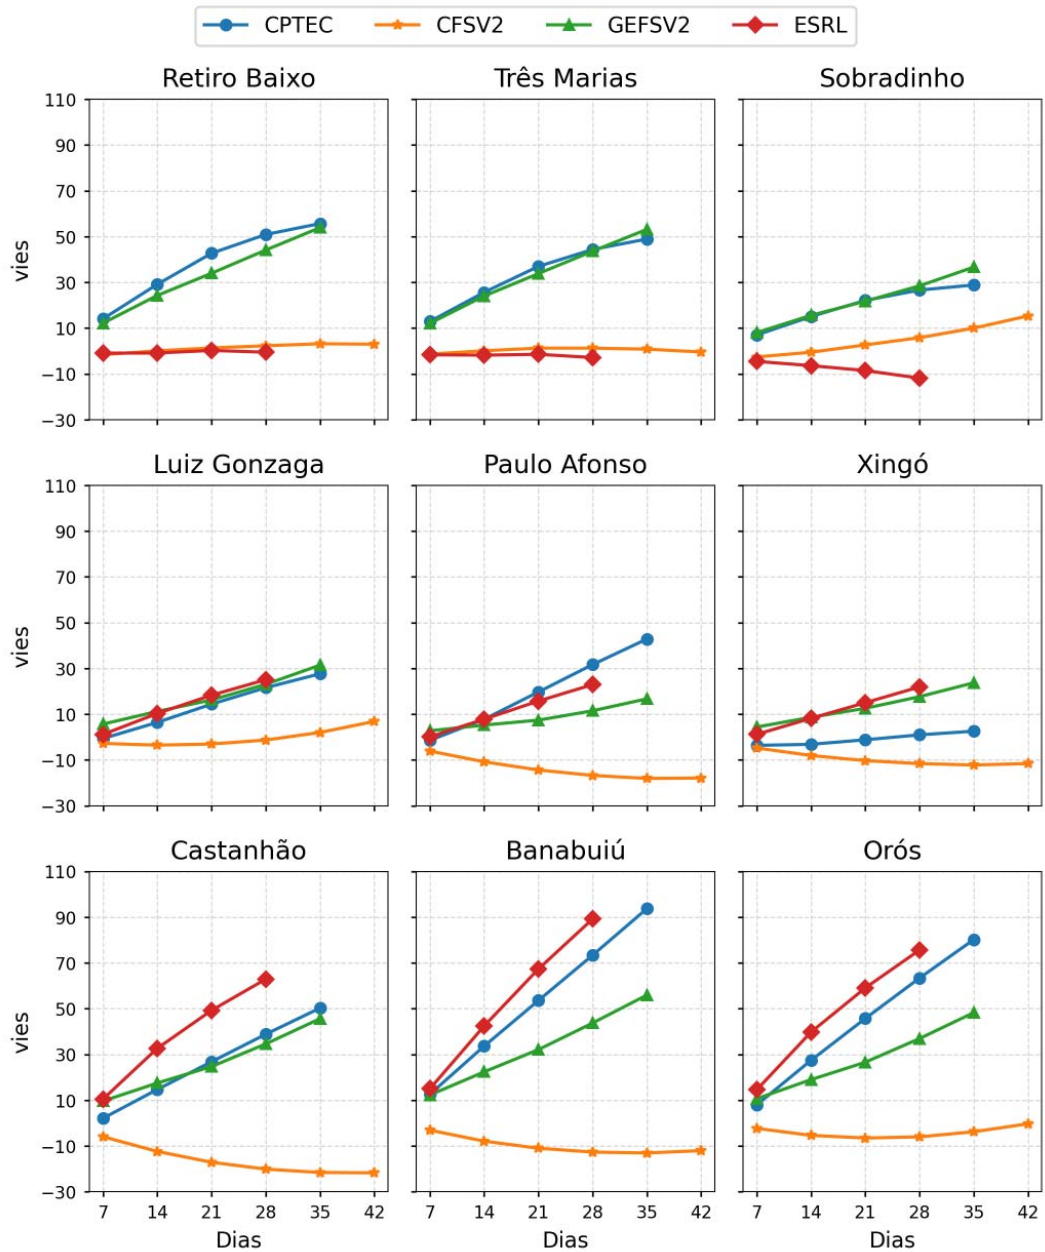
A Figura 25 apresenta o viés das previsões de precipitação para os meses de novembro a julho nas bacias estudadas.

As estimativas foram obtidas para diferentes horizontes de previsão, tendo em vista que os modelos adotam abordagens distintas para realizar suas previsões. O modelo ESRL, por exemplo, apresenta horizonte de previsão de até 32 dias, enquanto que os modelos CPTEC e GEFSv2 realizam previsões para até 35 dias. Já o modelo CFSv2 é capaz de fornecer previsões para um horizonte mais amplo, de até 44 dias.

Verifica-se que os modelos CPTEC e GEFSv2 apresentaram uma tendência a simular condições mais úmidas, com viés positivo, em todas as bacias estudadas. As maiores discrepâncias foram observadas nas bacias do Castanhão, Orós e Banabuiú, levando a uma superestimativa das precipitações no período avaliado. Por outro lado, o modelo CFSv2 demonstrou uma tendência a simular condições mais secas, com viés negativo, em praticamente todas as bacias, com exceção das bacias de Retiro Baixo, Três Marias e Sobradinho, onde o viés apresentou-se positivo para o acumulado de 14 a 42 dias. Ademais, o modelo ESRL evidenciou uma propensão a simular condições mais úmidas em quase todas as bacias, exceto nas bacias de Três Marias, Retiro Baixo e Sobradinho, onde foi verificado um viés negativo.

Além disso, foi possível observar uma tendência de aumento do viés à medida que se amplia o horizonte de previsão. Esse padrão foi verificado principalmente nos modelos do

Figura 25 – Viés das previsões de precipitação realizadas pelos modelos.



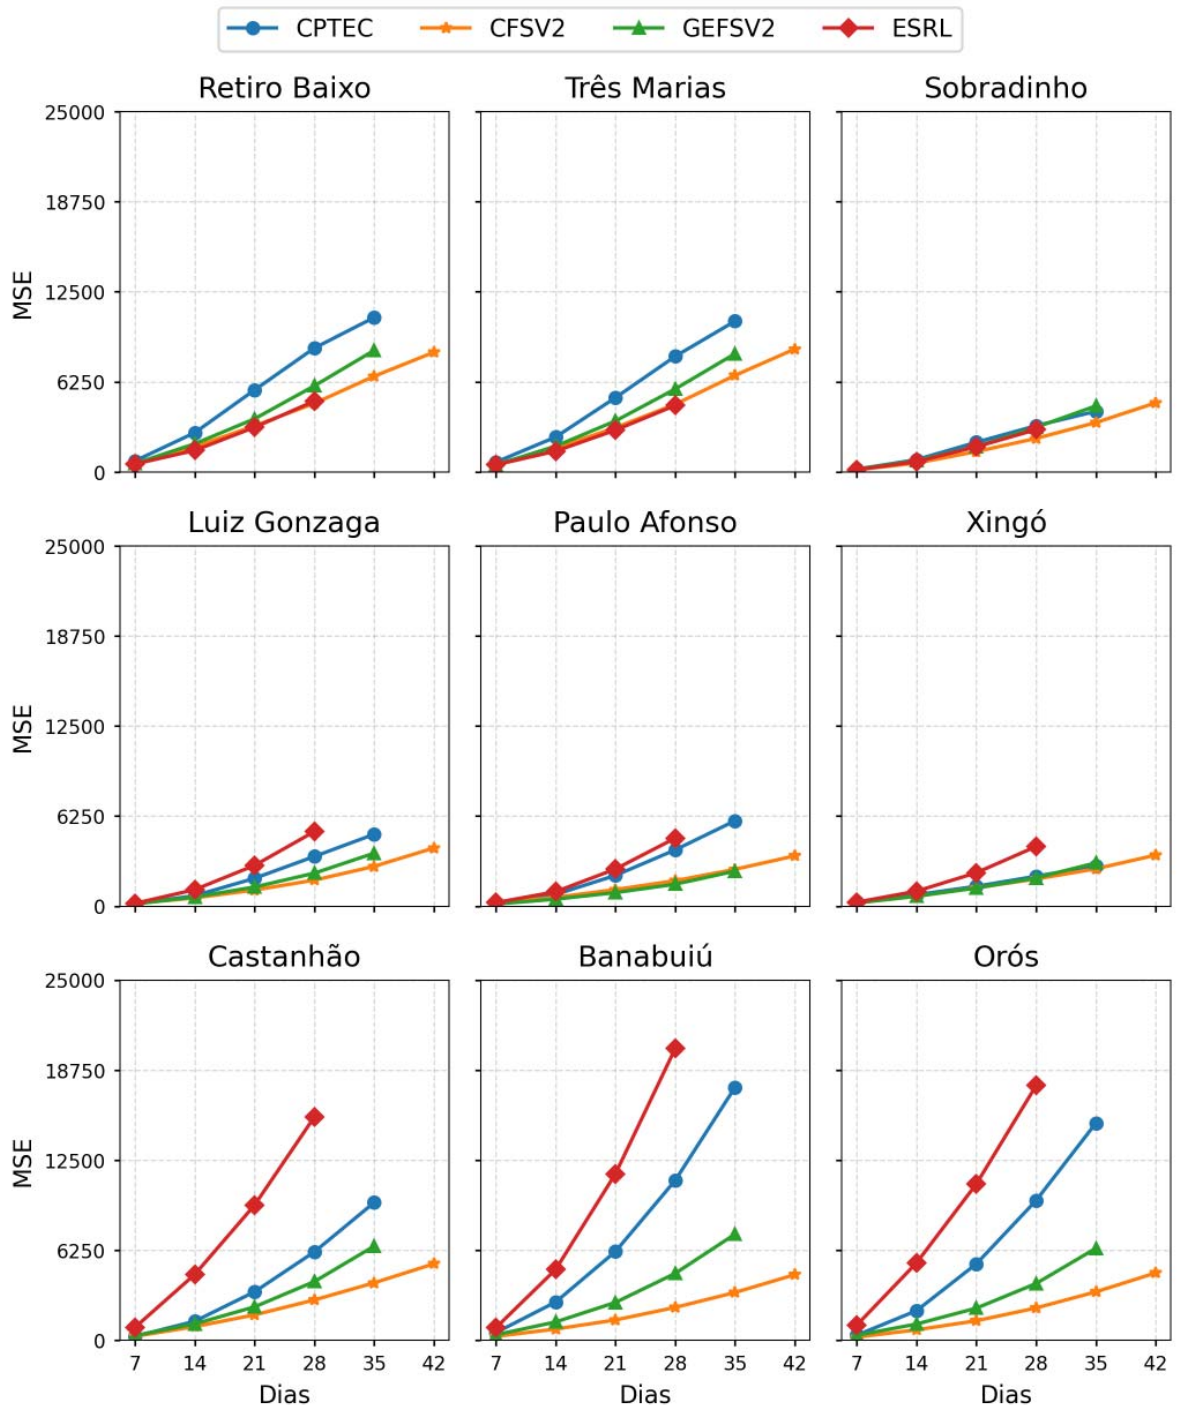
Fonte: Elaborado pelo Autor, 2023

CPTEC e GEFSv2, em todas as bacias analisadas, bem como no modelo ESRL, nas bacias do Luiz Gonzaga, Paulo Afonso, Xingó, Castanhão, Banabuiú e Orós. Entretanto, tal comportamento não foi observado no modelo CFSv2, no qual o viés apresentou variações menos expressivas em relação ao aumento do horizonte de previsão.

As Figuras 26 e 27 apresentam as avaliações de desempenho dos modelos, expressas pelo erro quadrático médio (MSE) e raiz do quadrado do erro médio (RMSE), respectivamente. De maneira geral, observa-se que os modelos tiveram desempenhos similares na bacia do São Francisco, já na bacia do Jaguaribe, foram observadas diferenças significativas entre os modelos.

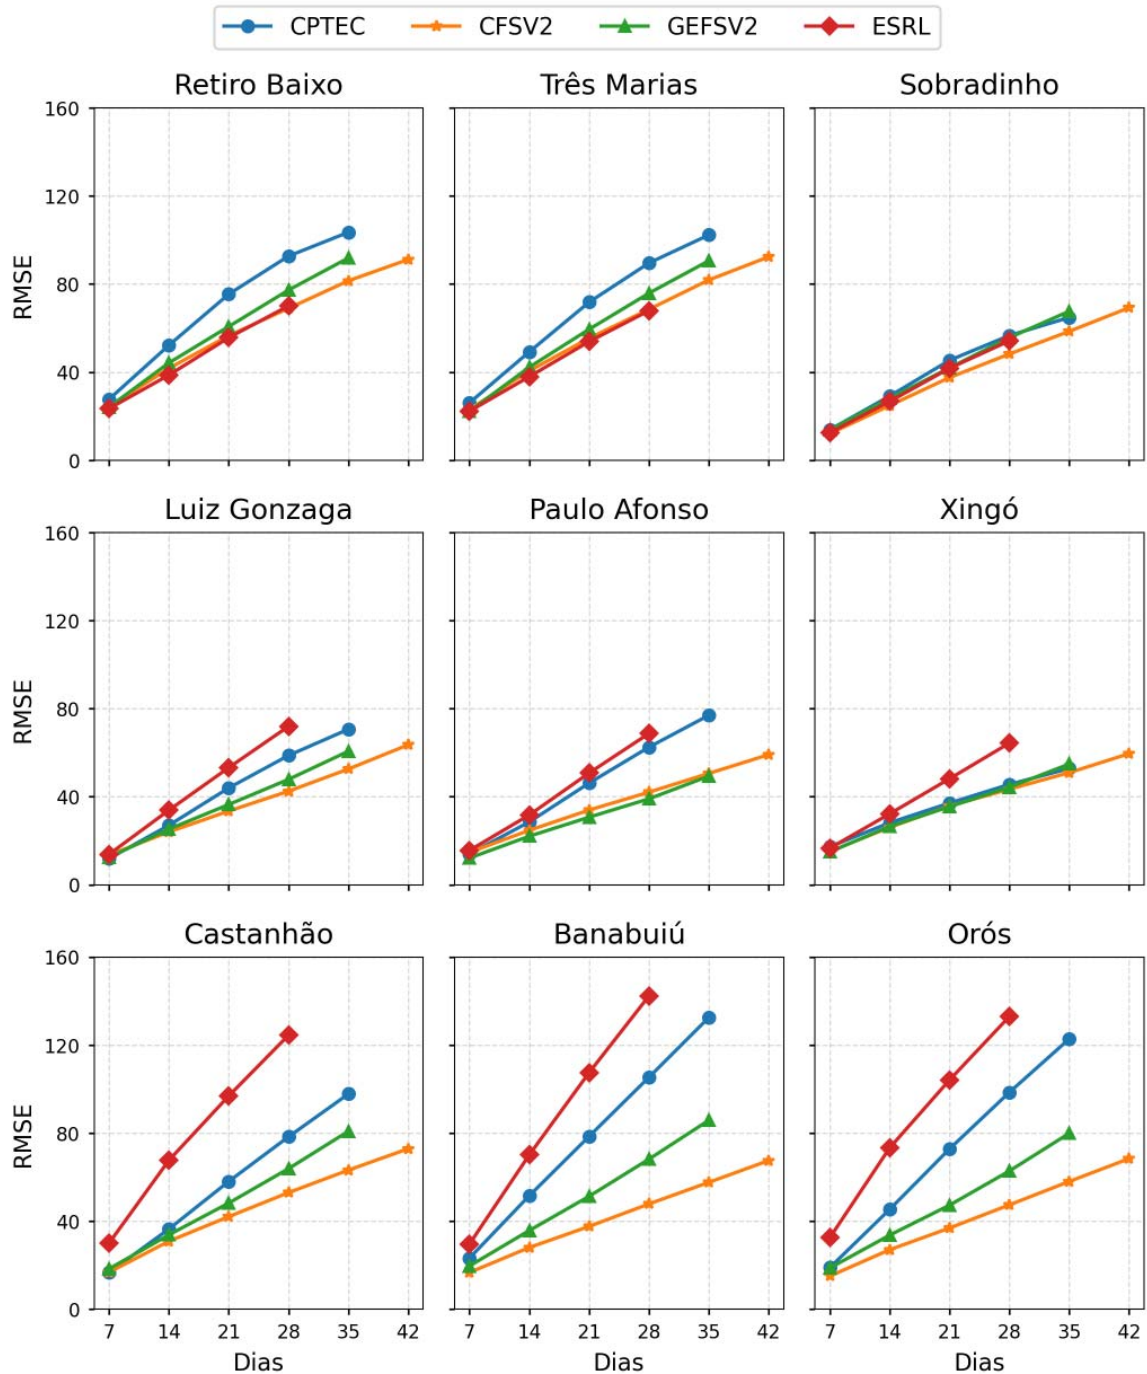
Observa-se um aumento progressivo no MSE e RMSE à medida que o horizonte de previsão se estende, o que indica que é mais difícil prever o clima com precisão em períodos mais longos. Esse comportamento é evidenciado pelo valor absoluto do MSE e do RMSE, que são significativamente maiores para o horizonte mais distante em comparação com os horizontes mais curtos.

Figura 26 – MSE das previsões de precipitação realizadas pelos modelos.



Fonte: Elaborado pelo Autor, 2023

Figura 27 – RMSE das previsões de precipitação realizadas pelos modelos.

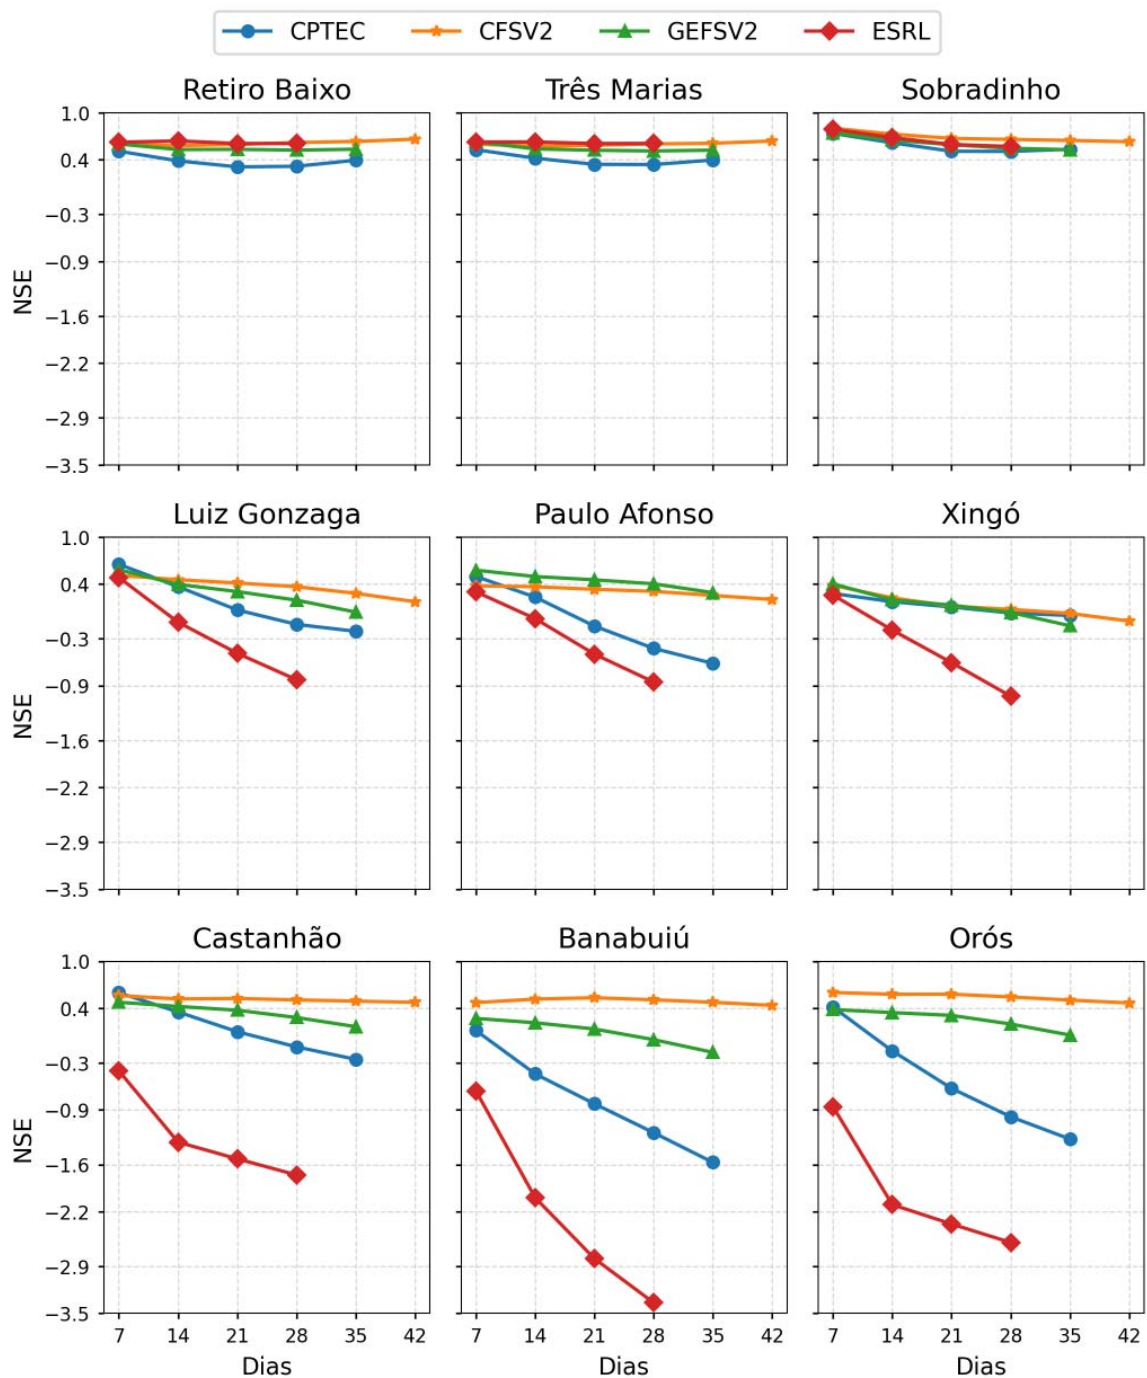


Fonte: Elaborado pelo Autor, 2023

Verifica-se também que os menores valores absolutos do MSE e do RMSE foram obtidos na bacia de Sobradinho, seguida pelas bacias de Xingó, Luiz Gonzaga e Paulo Afonso. Além disso, constatou-se que os modelos CFSv2 e GEFSv2 apresentaram um melhor desempenho em relação aos demais modelos. Entretanto, os modelos desenvolvidos pelo CPTEC e ESRL apresentaram dificuldades em representar as precipitações nas bacias do Orós, Banabuiú e Castanhão.

A Figura 28 apresenta a análise dos coeficientes de eficiência de Nash (NSE) dos modelos de previsão de precipitação. Observa-se que o desempenho dos modelos varia de acordo com a bacia e o horizonte considerado. Para as bacias do Retiro Baixo, Três Marias e Sobradinho, os modelos apresentaram valores de NSE entre 0,39 (CPTEC) e 0,8 (CFSv2) para horizontes mais curtos, enquanto que para horizontes mais distantes, o NSE variou entre 0,31 (CPTEC) e 0,64 (CFSv2), indicando concordância relativamente boa entre os dados observados e previstos.

Figura 28 – NSE das previsões de precipitação realizadas pelos modelos.



Fonte: Elaborado pelo Autor, 2023

Analisando as bacias do Xingó, Paulo Afonso e Luiz Gonzaga, percebe-se que o modelo do CPTEC apresentou baixa eficiência na bacia do Paulo Afonso, mas melhorou na bacia do Luiz Gonzaga, obtendo sua melhor eficiência na bacia do Xingó. O modelo ESRL mostrou eficiência muito baixa em todas as três bacias, enquanto os modelos CFSv2 e GEFSV2 apresentaram a melhor eficiência.

Para as bacias do Castanhão, Banabuiú e Orós, em geral, os modelos CFSv2 e GEFSV2 apresentaram uma melhor eficiência quando comparados aos modelos CPTEC e ESRL. A eficiência dos modelos CPTEC e ESRL foi muito baixa nas três bacias, enquanto que os modelos CFSv2 e GEFSV2 apresentaram eficiência moderada.

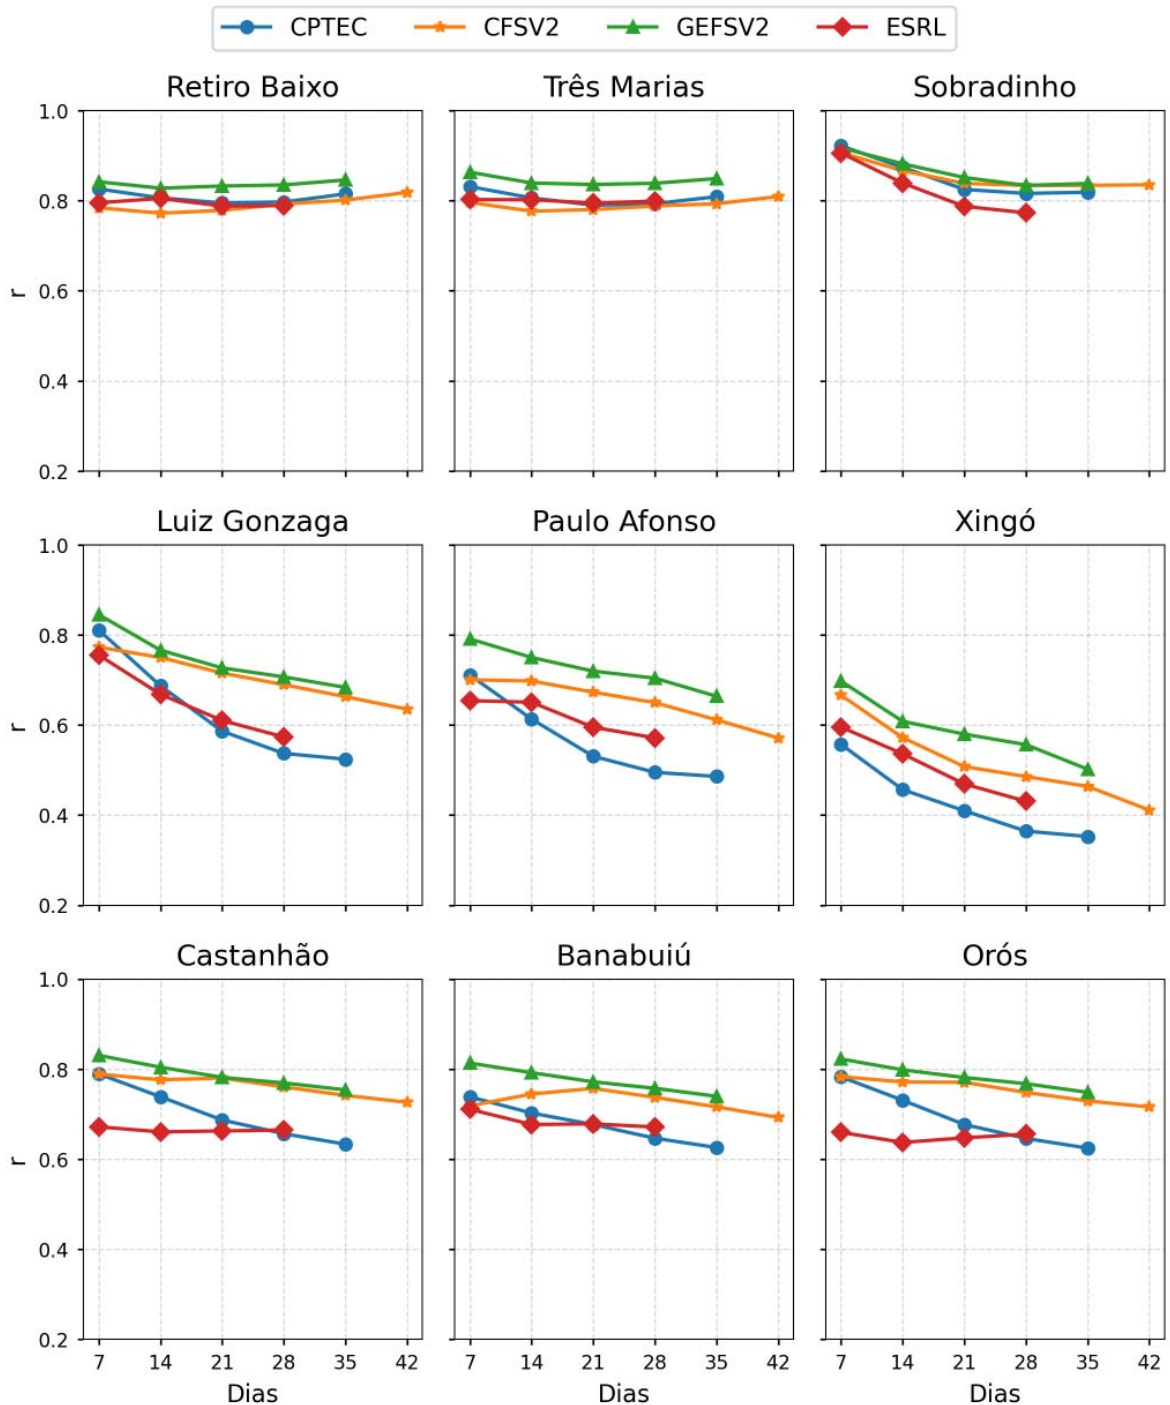
Entre os modelos avaliados, os modelos CFSv2 e GEFSV2 se destacam por manterem uma boa eficiência preditiva mesmo em horizontes de tempo mais distantes. Em contrapartida, os demais modelos analisados apresentaram uma diminuição significativa em sua eficiência à medida que aumenta o horizonte de previsão.

Por fim, a Figura 29 ilustra as avaliações de desempenho dos modelos, expressas pelo coeficiente de correlação de Pearson (r). Os resultados confirmam as observações das análises anteriores, indicando que as melhores correlações foram obtidas nas bacias de Retiro Baixo, Três Marias e Sobradinho. Para essas três bacias, todos os modelos apresentaram correlações superiores a 0,7 para todos os horizontes de previsão, evidenciando uma consistência no desempenho dos modelos.

Para as demais bacias, destaca-se que as correlações dos modelos GEFSv2 e CFSv2 apresentam-se superiores às dos demais modelos. No entanto, é importante notar que nas bacias do Luiz Gonzaga, Paulo Afonso e Xingó, as correlações apresentam uma diminuição significativa à medida que se amplia o horizonte de previsão. Este comportamento não é tão evidente nas demais bacias.

Assim como foi observado nas análises anteriores, constatou-se que os modelos CPTEC e ESRL apresentaram piores desempenhos nas bacias do Luiz Gonzaga, Paulo Afonso, Xingó, Castanhão, Banabuiú e Orós. Nessas bacias, as correlações desses modelos foram as menores, evidenciando limitações no desempenho dos modelos em representar o comportamento das precipitações nas bacias em questão.

Figura 29 – Coeficiente de correlação de Pearson (r) das previsões de precipitação realizadas pelos modelos.



3.5 Conclusões

Este capítulo teve como objetivo analisar as previsões sub-sazonais de quatro modelos hidrológicos em nove bacias hidrográficas. Os modelos avaliados foram o CPTEC, CFSv, GEFSv2 e ESRL, e as bacias hidrográficas estudadas foram Orós, Banabuiú, Castanhão, Xingó,

Luiz Gonzaga, Paulo Afonso, Sobradinho, Três Marias e Retiro Baixo. As previsões foram analisadas para horizontes de 7, 14, 21, 28, 35 e 42 dias, e as precipitações acumuladas foram o principal parâmetro avaliado.

Os resultados indicam que os modelos CFSv2 e GEFSv2 apresentaram desempenho superior em todas as bacias e para todos os horizontes de previsão analisados. Constatou-se também que os modelos do CPTEC e ESRL apresentaram limitações de desempenho, principalmente ao simular a precipitação acumulada nas bacias do Castanhão, Banabuiú e Orós.

Entender os vieses nos modelos climáticos é um desafio significativo para a comunidade científica. Isso ocorre porque esses vieses podem ter várias causas, incluindo a física do modelo, as condições iniciais e a modelagem dos processos físicos relevantes. Esses fatores afetam o balanço de radiação e água na superfície, tornando difícil determinar com precisão a causa subjacente do viés.

Peixoto *et al.* (1992) destacam que a modelagem climática é complexa, pois depende de muitos parâmetros físicos e processos dinâmicos interconectados. Essa complexidade pode tornar difícil a identificação de vieses específicos nos modelos. Além disso, a dinâmica climática é governada por muitos fatores, incluindo a interação entre a atmosfera, o oceano e a terra, o que pode aumentar a complexidade da modelagem.

É importante destacar que os resultados encontrados podem contribuir para aprimorar a gestão dos recursos hídricos nas regiões estudadas, uma vez que previsões sub-sazonais precisas são essenciais para o planejamento e tomada de decisão em diversas áreas, como agricultura, geração de energia hidrelétrica e abastecimento público, bem como orientar futuras pesquisas em modelagem hidrológica e previsão sub-sazonal de precipitação.

4 MODELAGEM HIDROLÓGICA VIA SMAP

4.1 Introdução

A água é um recurso natural fundamental para a sobrevivência humana e para o desenvolvimento econômico de uma região. No entanto, o crescente aumento da população tem levado a um aumento na demanda por água e, conseqüentemente, gerado preocupações sobre a sua disponibilidade e qualidade (CALDEIRA *et al.*, 2018).

Os usos múltiplos da água, muitas vezes sem restrições, associados à poluição dos corpos hídricos, têm contribuído para a escassez desse recurso e, por conseguinte, gerado perdas significativas na quantidade e qualidade da água. Setores como os de abastecimento público, industrial, mineração e agropecuário têm sofrido prejuízos econômicos e ambientais, que comprometem a manutenção de suas atividades e a qualidade de vida da população (MACIEL *et al.*, 2017).

Diante deste cenário, o monitoramento hidrológico se torna cada vez mais imprescindível para a gestão adequada dos recursos hídricos. Em particular, as informações sobre a vazão natural afluyente têm grande relevância para as tomadas de decisão (GUILHON *et al.*, 2007; VIOLA *et al.*, 2009).

Conceitua-se a vazão natural afluyente como a vazão que ocorre em uma seção de um rio sem a influência de intervenções humanas que possam alterar seu regime. Em outras palavras, essa é a vazão que seria observada na seção do rio se não houvesse a operação de reservatórios a montante, evaporação em lagos artificiais, ou retiradas de água para abastecimento e irrigação naquela região. Em suma, trata-se da vazão natural do rio, sem interferência humana (GUILHON *et al.*, 2007).

No setor agrícola, o monitoramento e a previsão de vazões naturais são fundamentais para assegurar a disponibilidade hídrica e caracterização das vazões que podem ser outorgadas para projetos de irrigação das lavouras e às atividades pecuárias. Adicionalmente, a previsão de vazões naturais têm papel relevante na gestão de riscos hidrológicos extremos, os quais podem impactar negativamente a produção agrícola (VIOLA *et al.*, 2009).

No contexto do Setor Elétrico, a previsão precisa de vazões é fundamental para permitir o uso eficiente dos diferentes modelos de operação, otimização e simulação energética, garantindo a avaliação precisa das condições operacionais das usinas hidrelétricas e termelétricas no futuro. Essa avaliação fornece informações valiosas para a tomada de decisões, permitindo a

exploração da capacidade hidrológica do Sistema Interligado Nacional (SIN) e maximizando seus ganhos sinérgicos (GOMES *et al.*, 2010; GUILHON *et al.*, 2007).

A modelagem hidrológica é uma ferramenta essencial para prever o comportamento dos recursos hídricos em uma bacia hidrográfica. Os modelos de chuva-vazão são um tipo específico de modelo hidrológico que utilizam informações de chuva e outros dados meteorológicos para simular a resposta hidrológica da bacia, incluindo a vazão dos rios. Esses modelos são usados em várias aplicações, incluindo previsão de enchentes e secas, planejamento de recursos hídricos e gestão de reservatórios.

Dentre os modelos hidrológicos desenvolvidos e aplicados para simulação hidrológica em diversas bacias hidrográficas, pode-se citar o *Soil and Water Assessment Tool* (SWAT) (STACKELBERG *et al.*, 2007; BORMANN *et al.*, 2007; GREEN *et al.*, 2006), o NRM3 Streamflow (NOTTER *et al.*, 2007), o *Annualized Agricultural NonPoint Source model* (AnnAGNPS) (LICCIARDELLO *et al.*, 2007), o Modelo Hidrológico de grande escala (MGB/IPH) (COLLISCHONN *et al.*, 2007) e o *Soil Moisture Accounting Procedure* (SMAP) (LOPES *et al.*, 1982).


Devido à sua capacidade de se adaptar a diferentes tipos de bacias hidrográficas e cenários climáticos, aliada à sua relativa simplicidade, o modelo hidrológico SMAP tem sido amplamente utilizado no Brasil para modelar o comportamento dos recursos hídricos em diversas regiões (SCHARDONG *et al.*, 2009). Desta forma, este capítulo tem por objetivo a calibração do modelo conceitual de chuva-vazão SMAP nas bacias hidrográficas do Orós, Castanhão, Banabuiú, Xingó, Luiz Gonzaga, Paulo Afonso, Sobradinho, Três Marias e Retiro Baixo.

4.2 O modelo SMAP

O *Soil Moisture Accounting Procedure* (SMAP) é um modelo hidrológico determinístico utilizado para simular a relação chuva-vazão em bacias hidrográficas. Criado por Lopes *et al.* (1982), o modelo foi inicialmente desenvolvido para intervalos de tempo diários e posteriormente foram disponibilizadas as versões horária e mensal, com aprimoramentos em sua estrutura.

Na versão diária, o modelo SMAP é composto por três reservatórios (conforme ilustrado na Figura 30). A dinâmica desse modelo é regida pela atualização do estado dos reservatórios a cada passo de tempo, o qual é descrito pela Equação 4.1.

Figura 30 – Estrutura do modelo SMAP na versão diária.



Fonte: Lopes (1999)

$$R_{solo}(i+1) = R_{solo}(i) + P - E_s - E_r - R_{ec} \quad (4.1)$$

$$R_{sup}(i+1) = R_{sup}(i) + E_s - E_d$$

$$R_{sub}(i+1) = R_{sub}(i) + R_{ec} - E_b$$

Em que:

- R_{solo} : Reservatório do solo (zona aerada) (mm);
- R_{sup} : Reservatório da superfície da bacia (mm);
- R_{sub} : Reservatório subterrâneo (zona saturada) (mm);
- P : Chuva (mm);
- E_s : Escoamento superficial (mm);
- E_d : Escoamento direto (mm);
- E_r : Evapotranspiração real (mm);
- R_{ec} : Recarga subterrânea (mm);
- E_b : Escoamento de base (mm).

A inicialização do reservatório do solo, superficial e subterrâneo, é dada por:

$$R_{solo}(1) = T_{uin} \cdot Str$$

$$R_{sup}(1) = 0$$

$$R_{sub}(1) = \frac{E_{bin}}{(1 - kk)/(A_d \cdot 86.4)}$$

Em que T_{uin} , é uma grandeza adimensional e representa o teor de umidade inicial do solo. E_{bin} é a vazão de base inicial em m^3/s e A_d é a área de drenagem em km^2 .

No processo de inicialização, é essencial estimar adequadamente o teor de umidade inicial do solo e o escoamento de base inicial. Essa etapa exige uma análise cuidadosa das características fisiográficas e climáticas da região da bacia hidrográfica em estudo, pois esses aspectos desempenham um papel fundamental na determinação do período inicial de calibração. Além disso, a escolha adequada desse período facilita o ajuste preciso da calibração ao hidrograma de vazão observada.

O modelo diário SMAP incorpora cinco funções de transferência, sendo que a separação do escoamento superficial é realizada com base no método estabelecido pelo SCS (*Soil Conservation Service do U.S. Department of Agriculture*), descritas pelas Equações 4.2 a 4.6.

1. Função de transferência do escoamento superficial (E_s)

$$\text{se, } P > A_i \quad \begin{cases} S = Str - R_{solo} \\ E_s = \frac{(P-A_i)^2}{(P-A_i+S)} \end{cases} \quad (4.2)$$

caso contrário, $E_s = 0$

2. Função de transferência da evapotranspiração real (E_r)

$$\text{se, } P - E_s > E_p \quad \{ E_r = E_p \quad (4.3)$$

caso contrário, $E_r = (P - E_s) + (E_p - (P - E_s)) \cdot T_u$

3. Função de transferência da recarga subterrânea (R_{ec})

$$\text{se, } R_{solo} > (Capc \cdot Str) \quad \{ R_{ec} = Crec \cdot T_u \cdot (R_{solo} - (Capc \cdot Str)) \quad (4.4)$$

caso contrário, $R_{ec} = 0$

4. Função de transferência do escoamento direto (E_d)

$$E_d = R_{sup} \cdot (1 - K_2) \quad (4.5)$$

5. Função de transferência do escoamento básico (E_b)

$$E_b = R_{sup} \cdot (1 - K_k) \quad (4.6)$$

Sendo:

$$T_u = \frac{R_{solo}}{Str}$$

$$K_k = 0.5^{\left(\frac{1}{k_k}\right)}$$

$$K_2 = 0.5^{\left(\frac{1}{k_2}\right)}$$

Por fim, o cálculo da vazão Q no dia, dada em m^3/s , é realizado por meio da Equação 4.7.

$$Q = (E_s + E_b) \cdot \frac{A_d}{86.4} \quad (4.7)$$

Os parâmetros calibrados pelo modelo são listados a seguir.

- Str - capacidade de saturação do solo (mm)
- K_{2t} - constante de recessão do escoamento superficial (dias)
- $Crec$ - parâmetro de recarga subterrânea (%)
- Ai - abstração inicial (mm)
- $Capc$ - capacidade de campo (%)
- K_{kt} - constante de recessão do escoamento básico (dias)

Em que K_{kt} representa a taxa de decaimento do escoamento ao longo do tempo após o término da chuva. O Ai é a quantidade de água que é retida na superfície antes de começar a ocorrer escoamento superficial. Já o $Capc$ corresponde a quantidade de água que o solo pode armazenar quando está completamente saturado. O fator $Crec$ está relacionado ao movimento da água na zona insaturada do solo e, portanto, é função do tipo do solo. O K_{2t} representa o tempo que leva para que o escoamento superficial diminua até um valor próximo a zero após uma precipitação. Por fim, o Str corresponde à quantidade máxima de água que o solo pode armazenar antes de começar a ocorrer escoamento superficial.

Vale ressaltar que as equações apresentadas neste tópico, referentes ao modelo hidrológico SMAP, foram desenvolvidas por Lopes *et al.* (1982) em seu artigo clássico sobre o modelo hidrológico SMAP. Para uma compreensão mais aprofundada sobre o modelo, recomenda-se consultar a obra original do autor.

Os modelos hidrológicos, tal como o SMAP, exigem a estimativa de parâmetros não diretamente mensuráveis, os quais são ajustados por meio de calibração para tornar as vazões simuladas concordantes com as vazões observadas na bacia. Esse processo é desafiador devido à não linearidade dos modelos e a incertezas nos dados (COLLISCHONN; TUCCI, 2003). A calibração pode ser realizada manualmente, com inferências e tentativa e erro, ou automaticamente, utilizando técnicas matemáticas para refinar os resultados e diminuir a subjetividade. As técnicas automáticas envolvem uma função objetivo, um algoritmo de otimização, um critério de finalização e os dados para calibração.

4.3 Metodologia

Os dados utilizados na calibração do modelo incluem medidas diárias de precipitação, vazão e evapotranspiração nas bacias de Retiro Baixo, Três Marias, Sobradinho, Luiz Gonzaga, Paulo Afonso, Xingó, Castanhão, Orós e Bababuiú. Os dados de precipitação e vazão foram fornecidas pela FUNCEME e pela ANA, enquanto os dados de evapotranspiração foram obtidos do *Centre for Environmental Data Analysis* (CEDA). O CEDA é responsável por reunir e catalogar conjuntos de dados climáticos observados, e está vinculada ao Centro Nacional de Ciência Atmosférica (NCAS) do Reino Unido. Mais informações sobre os dados catalogados pelo CEDA podem ser encontrados em (HARRIS *et al.*, 2020).

No presente estudo, foi escolhida a calibração automática para ajustar os 6 parâmetros do modelo SMAP. Desta forma as faixas de variação dos parâmetros foram previamente definidas com base nos estudos conduzidos por Lopes (1999). Os autores evidenciaram que em bacias brasileiras os parâmetros calibráveis variam dentro de uma faixa de valores específicos. Os limites dessas faixas de variação são mostrados na Tabela 1.

Tabela 1 – Limite de Variação dos Parâmetros do modelo SMAP Diário.

Parâmetros	Faixa de Variação	Unidades
Str	100 - 2000	<i>mm</i>
K_{2t}	0,2 - 10	dias
$Crec$	0 - 100	%
Ai	0 - 10	<i>mm</i>
$Capc$	0 - 60	%
K_{kt}	0 - 10	dias

Fonte: Lopes (1999)

Função Objetivo

No processo de calibração automática, o objetivo do modelo é encontrar o conjunto de parâmetros que otimize o valor numérico de uma função objetivo, visando minimizá-la ou maximizá-la. Essas funções objetivo são utilizadas como métricas para medir a discrepância entre os dados simulados pelo modelo e os dados observados na realidade.

As funções objetivo são escolhidas com base nas necessidades específicas da aplicação do modelo hidrológico. Algumas funções são mais sensíveis à precisão das vazões máximas, outras funções são especialmente utilizadas para avaliar o ajuste das vazões mínimas,

enquanto outras ainda consideram o desvio geral do volume total calculado em relação ao volume observado. Neste estudo, a função objetivo selecionada é o coeficiente de eficiência de *Nash-Sutcliffe*.

O coeficiente de eficiência de *Nash-Sutcliffe* (*Nash*) é uma medida estatística amplamente utilizada para avaliar a eficiência de modelos hidrológicos ao simular vazões observadas. Essa função é calculada comparando as vazões simuladas pelo modelo com as vazões observadas ao longo de uma série temporal. O *Nash* é dado por:

$$NSE = 1 - \frac{\sum_{t=1}^n (O_t - P_t)^2}{\sum_{t=1}^n (O_t - \bar{O})^2}$$

Em que O_t representa o valor da vazão observada no instante de tempo t , enquanto P_t corresponde ao valor da vazão prevista no mesmo instante de tempo. O parâmetro n indica o número total de registros, e \bar{O} representa a média das vazões observadas. Portanto, o objetivo do processo de calibração é encontrar, através de um algoritmo de otimização, um conjunto de parâmetros que maximize o valor do (*NSE*). No presente estudo optou-se pelo algoritmo de otimização PSO (*Particle Swarm Optimization*).

Algoritmo de otimização: Particle Swarm Optimization (PSO)

Os algoritmos de otimização constituem procedimentos lógicos criados para identificar os melhores valores dos parâmetros que são capazes de otimizar a função objetivo. O *Particle Swarm Optimization* (PSO), desenvolvido por Kennedy e Eberhart (1995), trata-se de um algoritmo de otimização que se inspira no comportamento social observado em revoadas de pássaros e cardumes de peixes. O conceito que rege o PSO é simular graficamente a coreografia de um bando de pássaros, com o objetivo de descobrir padrões que regem a capacidade dos pássaros de voar sincronizadamente e mudar repentinamente de direção com um reagrupamento.

No PSO, um conjunto de partículas (enxame), são distribuídas aleatoriamente e passam a movimentar-se através do espaço de busca. Cada uma dessas partículas é conduzida através do espaço por meio de duas forças distintas. A primeira força atrai a partícula para a melhor localização já encontrada por ela mesma, denominada *pbest* (melhor posição pessoal). A segunda força atrai a partícula para a melhor localização encontrada entre todos os membros do enxame, conhecida como *gbest* (melhor posição global). Ao longo do processo iterativo,

as partículas exploram o espaço de busca, ajustando suas posições e velocidades, visando a convergência para uma solução ótima ou próxima dela (NASCIMENTO *et al.*, 2012; KENNEDY; EBERHART, 1995).

Seja $x_i(t)$ a posição da partícula i no espaço de busca no intervalo de tempo t . A posição da partícula é alterada pela adição de uma velocidade, $v_i(t)$, à posição atual, ou seja,

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4.8)$$

É o vetor de velocidade que impulsiona o processo de otimização e reflete tanto o conhecimento experimental da partícula quanto as informações socialmente trocadas da vizinhança da partícula. Para o melhor $gbest$, a vizinhança de cada partícula é o enxame inteiro, e a informação social é a melhor posição encontrada pelo enxame, denominada $\hat{y}(t)$. A velocidade da partícula i é dada por:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_1(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_2(t)[\hat{y}(t) - x_{ij}(t)] \quad (4.9)$$

Em que $v_{ij}(t)$ é a velocidade da partícula i na dimensão $j = 1, \dots, n_x$ no tempo t ; $x_{ij}(t)$ é a posição da partícula i na dimensão j no tempo t ; c_1 e c_2 são constantes de aceleração que controlam a influência da velocidade individual e global; r_1 e r_2 são números aleatórios uniformemente distribuídos entre $[0, 1]$ usados para introduzir um elemento estocástico no algoritmo.

A melhor posição pessoal, y_i , associada à partícula i é a melhor posição que a partícula visitou desde o primeiro passo de tempo. Considerando os problemas de minimização, a melhor posição pessoal na próxima etapa de tempo, $t+1$, é calculada por:

$$y_i(t+1) = \begin{cases} y_i(t) & \text{se } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{se } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (4.10)$$

Em que $f: \mathbb{R}^{n_x} \rightarrow \mathbb{R}$ é a *fitness function* e mede o quão perto a solução correspondente está do ótimo. A melhor posição global, $\hat{y}(t)$, no intervalo de tempo t , é definida como:

$$\hat{y}(t) = \min\{f(y_0(t)), \dots, f(y_{n_s}(t))\} \quad (4.11)$$

Em que n_s representa o número total de partículas no enxame.

As equações apresentadas neste tópico são fundamentadas nas contribuições de Poli *et al.* (2007), que propuseram atualizações para o algoritmo de otimização desenvolvido por

Kennedy e Eberhart (1995). Detalhes mais abrangentes sobre o PSO podem ser encontrados na obra dos autores mencionados.

No processo de calibração e validação do SMAP, foram selecionados períodos simultâneos de dados de vazão, evapotranspiração e precipitação. Os períodos utilizados em cada fase estão detalhados na Tabela 2. Um período de 60 dias foi dedicado ao aquecimento do modelo. Durante o processo de calibração, o mês inicial foi estrategicamente escolhido para coincidir com uma estação seca, possibilitando assumir os valores E_{bin} e T_{uin} como sendo iguais a zero. Optou-se pelo mês de agosto para todas as bacias.

Tabela 2 – Períodos analisados

Bacia	Calibração	Validação
Retiro Baixo	01/08/1987 - 31/12/2001	01/08/2002 - 31/12/2015
Três Marias	01/08/1985 - 31/12/2000	01/08/2002 - 31/12/2015
Sobradinho	01/08/1985 - 31/12/2000	01/08/2002 - 31/12/2015
Luiz Gonzaga	01/08/1985 - 31/12/2000	01/08/2002 - 31/12/2015
Paulo Afonso	01/08/1981 - 31/12/1991	01/08/1992 - 31/12/2001
Xingó	01/08/1981 - 31/12/1991	01/08/1992 - 31/12/2001
Castanhão	01/08/1996 - 31/12/2004	01/08/2005 - 31/12/2011
Banabuiú	01/08/1994 - 31/12/2002	01/08/2003 - 31/12/2010
Orós	01/08/1986 - 31/12/1997	01/08/1998 - 31/12/2010

Fonte: Elaborado pelo Autor, 2023

Para a análise de desempenho do modelo, as vazões observadas foram comparadas com as vazões modeladas. O desempenho foi mensurado utilizando três índices estatísticos, os quais estão descritos no Tópico 3.3.2 deste trabalho. Para medir o grau de correlação entre as variáveis previstas e observadas, foi utilizado o coeficiente de correlação de Pearson (r). O índice de eficiência de *Nash-Sutcliffe* (*Nash*) foi empregado para determinar a proporção da variância observada que é explicada pelo modelo.

Foi realizado também o cálculo do percentual de viés ($Pbias$) das vazões simuladas em relação às observadas. Esse índice mede a tendência média dos valores simulados serem maiores ou menores do que os observados e é dado por:

$$Pbias = 100 \times \frac{\sum_{t=1}^n (S_t - O_t)}{\sum_{t=1}^n (O_t)} \quad (4.12)$$

Em que P representa a vazão prevista pelo modelo, O a vazão observada e n o tamanho da série. O valor ideal para o $Pbias$ é 0, e valores de baixa magnitude indicam uma

simulação precisa. Valores positivos indicam viés de superestimação, enquanto valores negativos indicam viés de subestimação do modelo.

4.4 Resultados

Na Tabela 3, são apresentados os índices estatísticos que avaliam o desempenho do modelo SMAP nas fases de calibração e validação das bacias hidrográficas estudadas.

Nas bacias de Retiro Baixo, Três Marias e Sobradinho, o desempenho do modelo foi bastante satisfatório, tanto no período de calibração quanto no período de validação. Especificamente, Retiro Baixo e Três Marias apresentaram bons resultados, com *Nash* e correlação relativamente altos, indicando um bom ajuste entre os dados simulados e observados em ambos os períodos. O *Pbias* relativamente baixo em Sobradinho revela que o modelo não apresentou viés significativo em suas previsões para esta bacia. No entanto, na fase de validação, o *Pbias* foi de 25% e 15% em Retiro Baixo e Três Marias, respectivamente, mostrando que o modelo tende a superestimar as vazões nestas bacias.

Tabela 3 – Indicadores de desempenho - SMAP

Bacia	Calibração			Validação		
	<i>Nash</i>	<i>r</i>	<i>Pbias</i> (%)	<i>Nash</i>	<i>r</i>	<i>Pbias</i> (%)
Retiro Baixo	0.64	0.81	15.26	0.61	0.81	25.4
Três Marias	0.61	0.80	15.27	0.68	0.84	14.98
Sobradinho	0.49	0.71	-5.25	0.59	0.77	6.47
Luiz Gonzaga	0.10	0.48	-46.28	0.34	0.66	15.71
Paulo Afonso	-0.01	0.33	-61.51	-0.14	0.14	-77.74
Xingó	-0.13	0.27	-84.28	-0.22	0.11	-88.37
Castanhão	0.45	0.67	-13.78	0.67	0.82	3.21
Banabuiú	0.50	0.71	-16.51	0.65	0.83	7.91
Orós	0.74	0.88	4.29	0.45	0.81	25.82

Fonte: Próprio autor

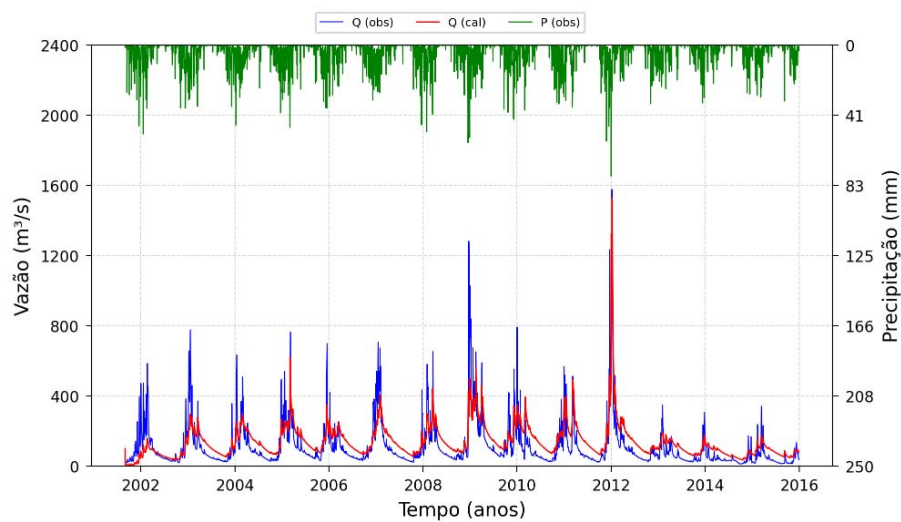
O SMAP também apresentou um bom desempenho nas sub-bacias do Jaguaribe. Durante a fase de validação, tanto Castanhão quanto Banabuiú exibiram um desempenho superior em relação à fase de calibração, demonstrando melhorias notáveis em todos os índices avaliados. Especificamente, essas bacias apresentaram valores de correlação próximos a 0,8 e *Nash* próximo de 0,65, indicando uma boa capacidade de reprodução do comportamento hidrológico ao longo do tempo. Além disso, o *Pbias* foi inferior a 8%, apontando que o modelo teve uma tendência mínima de viés em suas previsões.

Nas bacias de Luiz Gonzaga, Paulo Afonso e Xingó, o desempenho do SMAP foi

mais desafiador. Nessas bacias, os valores de *Nash* e *r* foram baixos, sugerindo que o modelo teve dificuldades em reproduzir com precisão as vazões observadas durante os períodos de calibração e validação. Além disso, o *Pbias* negativo e expressivo indica uma tendência significativa de subestimação nas previsões.

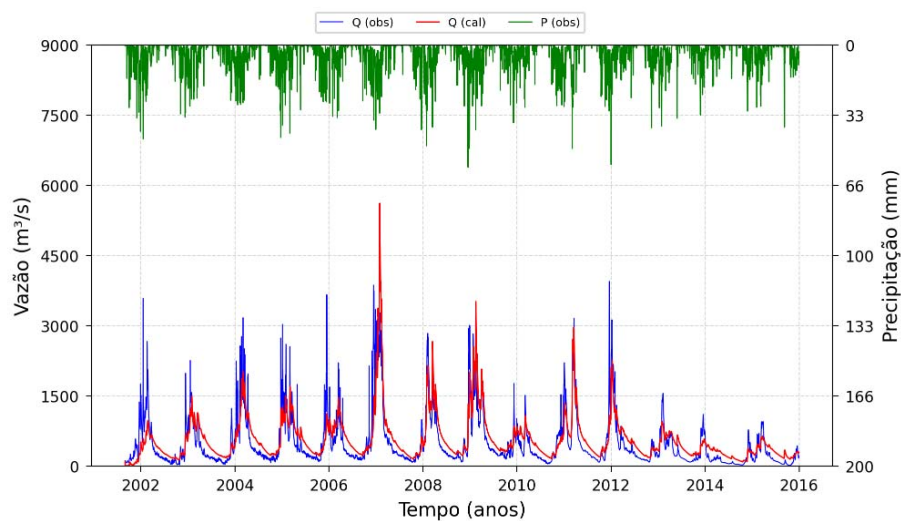
Nas Figuras 31 a 39, são apresentados os hidrogramas observados e calculados pelo modelo nas sub-bacias estudadas durante a etapa de validação. Além disso, é mostrada a série de precipitação observada acumulada em 24 horas para o mesmo período. Os gráficos referentes ao período de calibração podem ser visualizados no Anexo A deste trabalho.

Figura 31 – Bacia do Retiro Baixo - Validação SMAP.




Fonte: Próprio autor.

Figura 32 – Bacia de Três Marias - Validação SMAP.




Fonte: Próprio autor.

Figura 33 – Bacia de Sobradinho - Validação SMAP.




Fonte: Próprio autor.

Figura 34 – Bacia de Luiz Gonzaga - Validação SMAP.




Fonte: Próprio autor.

Figura 35 – Bacia de Paulo Afonso - Validação SMAP.




Fonte: Próprio autor.

Figura 36 – Bacia de Xingó - Validação SMAP.



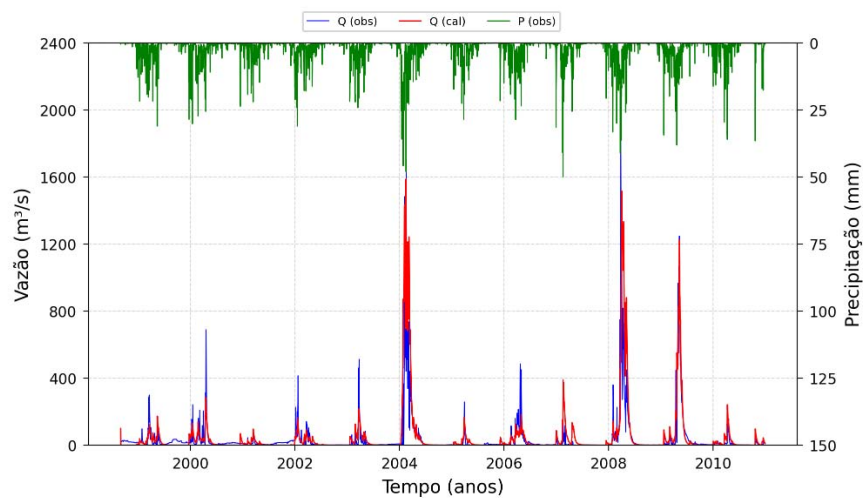
Fonte: Próprio autor.

Figura 37 – Bacia do Castanhão - Validação SMAP.




Fonte: Próprio autor.

Figura 38 – Bacia do Orós - Validação SMAP.



Fonte: Próprio autor.

Figura 39 – Bacia do Banabuiú - Validação SMAP.



Fonte: Próprio autor.

Nas Figuras 31 e 32, pode-se observar, em períodos de estiagem, uma leve superestimação das vazões nas bacias de Retiro Baixo e Três Marias. Fica também evidente o péssimo desempenho do modelo nas bacias de Luiz Gonzaga, Paulo Afonso e Xingó (Figuras 34, 35 e 36). Nesses casos, o modelo não consegue captar adequadamente os picos de vazões, resultando em uma discrepância considerável entre as vazões simuladas e observadas. Além disso, a ausência de um padrão sazonal definido nas vazões torna a modelagem dessas bacias um processo ainda mais desafiador, exigindo esforços adicionais para aprimorar as previsões nessas regiões.

Os parâmetros do modelo: capacidade de saturação do solo (Str), a constante de recessão do escoamento superficial (K_{2t}), o parâmetro de recarga subterrânea ($Crec$), a abstração inicial (Ai), a capacidade de campo ($Capc$) e a constante de recessão do escoamento básico (K_{kt}), obtidos na etapa de calibração das bacias analisadas, são apresentados na Tabela 4.

Tabela 4 – Parâmetros do modelo SMAP após calibração

Bacia	Str	K_{2t}	$Crec$	Ai	$Capc$	K_{kt}
Retiro Baixo	1245.1306	4.6669	0.1695	0.2823	0.9404	0.1174
Três Marias	919.626	5.7713	0.2466	0.0176	0.8214	0.3306
Sobradinho	899.5406	19.7462	0.1398	0.0772	0.7086	2.8421
Luiz Gonzaga	209.7882	14.5117	0.555	0.0321	0.4663	2.5736
Paulo Afonso	205.7729	4.8977	0.9923	0.176	0.2358	0.8971
Xingó	100.7148	16.8202	0.9906	0.1258	0.0008	2.5806
Castanhão	348.9156	5.8716	0.0004	0.4337	0.3377	3.9113
Banabuiú	287.2909	4.4975	0.0003	0.0327	0.7208	2.7577
Orós	333.0105	6.6994	0.0108	2.4385	0.5166	0.1714

Fonte: Elaborado pelo autor, 2023

4.5 Conclusões

O presente estudo teve como objetivo a calibração do modelo *Soil Moisture Accounting Procedure (SMAP)* para a bacia hidrográfica do rio São Francisco e para três sub-bacias do Jaguaribe. Para tal, foi empregado o método de calibração automático, em que utilizou-se o algoritmo *Particle Swarm Optimization (PSO)* como ferramenta para otimizar o processo de ajuste dos parâmetros do modelo.

Os resultados obtidos demonstram que o modelo SMAP foi eficaz na simulação hidrológica das Bacias de Retiro Baixo, Três Marias, Sobradinho, Castanhão, Banabuiú e Orós. Nessas bacias, o modelo apresentou uma boa precisão ao capturar o ciclo sazonal das vazões, representando as tendências das séries e capturando os picos de vazão. Esses resultados evidenciam a robustez do modelo nessas regiões.

Para estas bacias, os valores dos índices de desempenho apresentaram-se em níveis satisfatórios. Em particular, os valores de *Nash* e da correlação, indicando uma boa concordância entre as vazões simuladas e observadas, evidenciando a capacidade do modelo em capturar a variabilidade e as flutuações sazonais das vazões. Além disso, o percentual do viés mostrou que as diferenças entre as vazões simuladas e observadas são relativamente pequenas, corroborando a adequação do modelo para reproduzir os comportamentos hidrológicos na região.

No entanto, os resultados obtidos para as Bacias de Luiz Gonzaga, Paulo Afonso e Xingó revelaram desafios significativos na modelagem hidrológica dessas áreas. O desempenho do modelo SMAP nessas bacias foi considerado insatisfatório, especialmente incluindo a dificuldade em capturar os picos de vazão. Um aspecto notável nessas bacias é a presença de séries de vazão altamente irregulares, sem um padrão sazonal definido, diferindo das demais bacias hidrográficas estudadas. Diante dessa complexidade nas séries de vazão, o modelo SMAP encontrou limitações em sua capacidade de ajuste e reprodução adequada das vazões.

Portanto, os resultados apontam que o modelo SMAP apresenta um bom desempenho na simulação das bacias com padrões hidrológicos mais definidos. Contudo, sua aplicação nas Bacias de Luiz Gonzaga, Paulo Afonso e Xingó revelou desafios significativos devido à complexidade e variabilidade hidrológica observada nessas regiões. Essa constatação destaca a necessidade de uma análise mais aprofundada das particularidades hidrológicas dessas áreas, bem como a exploração de outras técnicas de modelagem de vazão mais adequadas para lidar com padrões hidrológicos mais complexos.

5 REDES NEURAIS

5.1 Introdução

As Redes Neurais Artificiais (RNAs) são modelos computacionais baseados no sistema nervoso dos seres vivos. Entre suas características, destacam-se o paralelismo de suas atividades, a alta conectividade e a capacidade elevada em descrever sistemas não-lineares através do método de treinamento, o que permite a rede aprender os comportamentos e extrair o relacionamento existente entre as variáveis envolvidas.

Os primeiros estudos com RNAs datam de 1943, quando McCulloch e Pitts (1943) produziram o primeiro modelo matemático inspirado no neurônio biológico, resultando assim na primeira concepção de neurônio artificial.

Hebb (1949) dando continuidade às pesquisas, propôs o primeiro método de treinamento para RNAs, que foi denominado de regra de aprendizado de Hebb, sendo esta baseada em hipóteses e observações de caráter neurofisiológico. Nessa publicação, foi sugerida pela primeira vez a utilização de pesos para assimilação do conhecimento pelas RNAs. A Equação 5.1 expressa matematicamente o enunciado da lei de aprendizagem de Hebb.

$$\nabla W_i = \eta x_i y(x). \quad (5.1)$$

Em que η é o fator de aprendizagem, x_i a i -ésima entrada do neurônio (valor do neurônio pré-sináptico) e $(y(x))$ é o valor do neurônio pós-sináptico.

Diversos outros pesquisadores continuaram o trabalho de desenvolvimento de modelos matemáticos fundamentados no neurônio biológico, gerando uma série de estruturas e algoritmos de aprendizado. Destaca-se o modelo proposto por Rosenblatt (1958) denominado *Perceptron*.

Devido à capacidade de reconhecer padrões relativamente simples, o modelo *Perceptron* despertou o interesse de outros pesquisadores. Widrow e Hoff (1960) desenvolveu um tipo de rede denominada *Adaline*, baseada no conceito do erro médio quadrático. Nesta arquitetura o ajuste dos pesos da rede foi realizado através de uma aproximação linear do cálculo do gradiente de uma função de erro quadrática, conhecida como Regra Delta. A Equação 5.2 expressa matematicamente esta regra de aprendizagem do delta.

$$E(t) = (y_d - y(x)) \quad (5.2)$$

$$W(t+1) = W(t) - \eta \frac{\partial E(t)}{\partial t} \quad (5.3)$$

Onde t é a iteração do treinamento, y_d é a saída desejada, $y(x)$ é a saída do neurônio, $W(t)$ são os pesos na iteração t e $\frac{\partial E(t)}{\partial t}$ é o gradiente do erro na iteração t .

Minsky e Papert (1969) demonstraram de forma enfática as limitações de RNAs constituídas de apenas uma única camada, como o *Perceptron* e o *Adaline* para resolver problemas não linearmente separáveis. Desde então houve uma certa estagnação nas pesquisas. Somente no final dos anos 1980, com o desenvolvimento de computadores com maior capacidade de processamento, Rumelhart *et al.* (1986) desenvolveram um algoritmo que permitia ajustar os pesos em uma rede com mais de uma camada, solucionando-se o antigo problema de aprendizado dos padrões. Tal arquitetura foi denominada *backpropagation* e motivou definitivamente as pesquisas em RNAs.

Devido a sua grande capacidade de representar modelos não lineares, particularmente em estudos de previsão de séries temporais, as RNAs tem se mostrado uteis na previsão de séries temporais de vazão e demais variáveis climatológicas. As RNAs já foram utilizadas para: (a) previsão de vazões: (Ballini *et al.* (2003); Gomes *et al.* (2010); Sousa e Sousa (2010); Araújo *et al.* (2005); Ribeiro (2011); Figueiredo *et al.* (2007); Bravo *et al.* (2008), SANTOS *et al.* (2022)); (b) previsão de precipitação (Dantas *et al.* (2016); Salame *et al.* (2019); Sousa *et al.* (2017); Borella *et al.* (2022); Aksoy e Dahamsheh (2009)); (c) anomalias de temperatura da superfície do mar (Zhang *et al.* (2020); Wu *et al.* (2006); Castro *et al.* (2020); Tangang *et al.* (1997)); entre outros.

O presente capítulo tem como propósito a elaboração de modelos de previsão utilizando Redes Neurais Artificiais (RNAs) e uma abordagem adicional que utiliza uma Rede Neural com pré-processamento baseado em *wavelets*. O objetivo é estimar as vazões nas bacias hidrográficas de Retiro Baixo, Três Marias, Sobradinho, Luiz Gonzaga, Paulo Afonso, Xingó, Castanhão, Orós e Banabuiú.

Nesse contexto, busca-se explorar o potencial das RNAs como ferramentas eficazes na previsão hidrológica, permitindo uma melhor compreensão e monitoramento dos recursos hídricos nessas bacias. Além disso, a incorporação do pré-processamento com *wavelets* tem o intuito de aprimorar o desempenho dos modelos, permitindo capturar características relevantes das séries de vazão e proporcionar uma maior precisão nas estimativas.

Diante da grande abrangência sobre o assunto e da diversidade de detalhes envolvidos, procurar-se-á focar apenas os aspectos mais importantes das RNA's, enfatizando as informações necessárias para o desenvolvimento desta pesquisa.


5.1.1 Neurônios Biológicos

O cérebro é o centro responsável pelo controle e processamento de informações dos seres humanos, ele é regido por unidades processadoras elementares que recebem continuamente informações de outras unidades, percebe-as e toma decisões apropriadas para cada uma de suas funcionalidades, tais como o andar e o pensar.

A célula elementar do sistema nervoso cerebral é o neurônio e seu papel se resume em conduzir estímulos elétricos. Os neurônios podem ser divididos basicamente em três partes principais, que são: o corpo celular, os dendritos e o axônio.

O corpo celular ou soma (Figura 40), é onde acontece o processamento de todas as informações que chegam ao neurônio, a fim de se produzir um potencial de ativação que indicará se o neurônio produzirá um impulso ao longo do seu axônio. É também no corpo celular que se encontram as principais organelas citoplasmáticas (núcleo, mitocôndrias, lisossomos, etc.) do neurônio.

Figura 40 – Modelo de Neurônio Biológico



Fonte: Silva *et al.* (2010).

Os dendritos é uma forma de prolongamento do corpo celular e é constituído por vários ramos que formam a árvore dendrital, sua principal função é captar continuamente os estímulos advindos dos outros neurônios ou do meio externo onde estão imersos e transmitir tais estímulos ao corpo celular.

O axônio é constituído por um único prolongamento, seu papel é transmitir os impulsos elétricos vindos do corpo celular para a extremidade do neurônio. A extremidade do axônio é constituída por ramificações denominadas sinapses cuja finalidade é transmitir os impulsos elétricos do axônio de um neurônio para os dendritos de outros neurônios.

Vale salientar que não existe contato entre as ramificações sinápticas de um neurônio

e os dendritos de outro neurônio, sendo que substâncias neurotransmissoras existentes entre os neurônios são as responsáveis por ponderar a transmissão de estímulos de um neurônio para outro.


De modo geral, Amari *et al.* (2003) classifica que a soma e os dendritos formam a superfície de entrada de um neurônio, enquanto que o axônio forma a superfície de saída do fluxo de informações.

5.1.2 Neurônios Artificiais

A estrutura das redes neurais artificiais foi desenvolvida a partir do princípio de funcionamento do cérebro humano. Os elementos processadores das redes neurais que tem um papel similar aos neurônios biológicos são chamados de neurônios artificiais.

O modelo de neurônio artificial mais simples, representado na Figura 41, foi proposto por McCulloch e Pitts (1943). Conhecido como *Perceptron*, ele reúne as principais características do neurônio biológico e é o modelo mais utilizado nos mais variados tipos de redes neurais.

Figura 41 – Neurônio Artificial



Fonte: Silva *et al.* (2010).

No modelo proposto, os diversos componentes podem ser comparados aos elementos do neurônio biológico. Os sinais representados pelo conjunto $\{X_1, X_2, \dots, X_n\}$ são os dados de entrada advindos do meio externo que são similares aos impulsos captados pelos dendritos do neurônio biológico.

As substâncias neurotransmissoras do neurônio biológico, responsáveis por ponderar a transferência de estímulos de um neurônio para outro, são representadas no neurônio artificial pelo conjunto de pesos sinápticos $\{W_1, W_2, \dots, W_n\}$.

A forma pela qual a rede pondera cada dado de entrada X_i e caracteriza a relevância

dada a esses dados pelos seus respectivos pesos sinápticos W_i é dada pela Equação 5.4.

$$u = \sum_{i=1}^n W_i \cdot X_i - \theta. \quad (5.4)$$

Em que $\{u\}$ é o potencial de ativação, que designará se o neurônio produzirá um potencial excitatório ou inibitório, e $\{\theta\}$ é o limiar de ativação, que especifica qual será o patamar apropriado para que o resultado produzido pelo somatório possa gerar um valor de disparo em direção à saída do neurônio.

O potencial de ativação é então passado para a função de ativação, retornando a saída y , dada pela Equação 5.5.

$$y = g(u). \quad (5.5)$$

A função de ativação tem por objetivo limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional.

Existe uma grande gama de funções de ativação utilizadas nas aplicações de RNAs, entre as mais utilizadas destacam-se: função Linear (5.6); Função Sigmoid (5.7); Função Tangente Hiperbólica (5.8) e a Função ReLU (5.9) (SILVA *et al.*, 2010).

$$g(u) = u \quad (5.6)$$

$$g(u) = \frac{1}{1 + e^{-u}} \quad (5.7)$$

$$g(u) = \frac{2}{1 + e^{-2u}} - 1 \quad (5.8)$$

$$g(u) = \max(0, u) \quad (5.9)$$

A função linear gera saídas que são iguais aos valores do potencial de ativação. Por sua vez, a função sigmoid produz saídas que sempre variam entre 0 e 1. A função tangente hiperbólica é similar à função sigmoid, mas mapeia os valores de entrada para o intervalo entre -1 e 1. Por fim, a função Relu retorna zero para valores negativos e preserva os valores positivos (AGGARWAL *et al.*, 2018).

5.1.3 Arquiteturas de RNAs


A arquitetura de uma rede neural é definida pela forma como os seus neurônios estão distribuídos ao longo da rede. Segundo Silva *et al.* (2010) basicamente, uma rede neural pode ser dividida em três partes, denominadas camadas, que são classificadas da seguinte forma:

- Camada de entrada: Camada que recebe as informações advindas do meio externo.
- Camadas escondidas, intermediárias, ocultas ou invisíveis: São aquelas responsáveis por extrair as características associadas ao processo. Basicamente quase todos os processos da rede são realizados nessa camada.
- Camada de saída: Camada responsável pela produção e apresentação dos resultados finais da rede.

Haykin (2007) classifica as arquiteturas das redes neurais considerando a disposição dos seus neurônios e o tipo de algoritmo utilizado na fase de treinamento da rede. Dentre as principais arquiteturas encontradas na literatura, as redes alimentadas adiante, Redes Neurais Recorrentes e as Redes de Memória de Longo Prazo destacam-se na implementação de modelos de regressão (SILVA *et al.*, 2010).

As redes alimentadas adiante podem ser do tipo camada única ou com múltiplas camadas. A rede com uma única camada ou *feedforward* de camada simples, é representada na Figura 42.

Figura 42 – Exemplo de rede feedforward de camada única




Fonte: Silva *et al.* (2010).

Nesse tipo de arquitetura a rede possui apenas uma única camada de entrada e uma única camada de neurônio que é a própria camada de saída. O fluxo de informações na arquitetura da rede alimentada a diante com camada única segue sempre numa única direção, da camada de entrada em direção à camada de saída. Entre os principais tipos de redes que utilizam esse tipo de arquitetura destacam-se o *Perceptron* e o *Adaline*.

A Figura 43 apresenta a rede alimentada adiante com múltiplas camadas. Também denominadas de *feedforward* de camadas múltiplas, como o próprio nome da rede sugere, essas arquiteturas são constituídas por uma ou mais camadas escondidas de neurônios.

Figura 43 – Exemplo de rede feedforward de camadas múltiplas



Fonte: Silva *et al.* (2010).


Conforme observado na Figura 43, nesse tipo de rede não há realimentação nas camadas neurais, pois a propagação do processamento neural é unidirecional. O fluxo de informações inicia-se na camada de entrada, percorre as camadas intermediárias e finaliza nas camadas de saída.

Em resumo a rede funciona da seguinte forma: Os estímulos advindos do meio externo são captados pelas camadas de entrada. As camadas intermediárias extraem as informações mais relevantes referentes ao comportamento e as codificam por meio de seus pesos sinápticos e limiares de seus neurônios. Finaliza-se o processo na camada de saída onde os neurônios desta camada recebem as informações processadas nas camadas anteriores e produzem um padrão de resposta que será a saída processada pela rede.

Na Rede Neural Recorrente (*Recurrent Neural Networks - RNNs*), representada na Figura 44, ocorre um fenômeno conhecido como retroalimentação, em que os sinais retornam para camadas anteriores. Essa estrutura de *feedback* permite que a rede capture dependências temporais e seja especialmente adequada para lidar com dados sequenciais. A presença desses ciclos de retroalimentação torna o treinamento mais desafiador, mas também confere às redes recorrentes a capacidade de aprender padrões complexos ao longo do tempo. Esse tipo de conexão, em que as informações fluem de uma camada para outra e, ao mesmo tempo, há uma realimentação que permite que informações anteriores influenciem as saídas atuais (SILVA *et al.*, 2010).


A Redes de Memória de Longo Prazo (*Long Short-Term Memory - LSTM*), apresentada na Figura 45, é uma arquitetura de rede neural recorrente projetada para lidar com o desafio de capturar dependências de longo prazo em sequências de dados. Diferentemente das redes

Figura 44 – Exemplo de rede neural recorrente



Fonte: Silva *et al.* (2010).

neurais recorrentes tradicionais, que podem ter dificuldades em lembrar informações relevantes ao longo do tempo, as LSTMs são desenvolvidas para manter e atualizar memórias ao longo de sequências extensas.

Figura 45 – Exemplo de *Long Short-Term Memory*

Fonte: Olah (2015).

Uma LSTM possui uma unidade de memória especializada chamada célula de memória. Essa célula de memória é capaz de armazenar informações relevantes e descartar informações irrelevantes, permitindo que a rede aprenda a manter um contexto a longo prazo. As LSTMs utilizam portões, que são mecanismos de controle, para regular o fluxo de informações dentro da célula de memória. Esses portões determinam quais informações devem ser lembradas, quais informações devem ser atualizadas e quais informações devem ser emitidas como saída.

Essa capacidade de lembrar informações relevantes de longo prazo torna as LSTMs especialmente eficazes em tarefas que envolvem dados sequenciais, como processamento de linguagem natural e análise de séries temporais (AGGARWAL *et al.*, 2018).

5.1.4 *Treinamentos de RNAs*

O processo pelo qual os parâmetros livres de uma rede neural são adaptados através de estímulos que os neurônios recebem do ambiente onde estão inseridos é denominado treinamento.

Segundo Haykin (2007) os processos interativos de ajustes dos pesos sinápticos desenvolvidos durante a fase de treinamento permitem a rede neural aprender sobre seu ambiente.

Silva *et al.* (2010) descrevem que durante o processo de treinamento a rede neural é capaz de aprender a partir dos padrões comportamentais das amostras de entrada e saída tornando-a capaz de generalizar soluções e produzir uma saída próxima daquela esperada.

De modo geral o processo de treinamento consiste na aplicação de passos ordenados (algoritmos de aprendizagem) para sintonização dos pesos sinápticos e limiares de seus neurônios tendo-se como objetivo a generalização de soluções a serem produzidas por suas saídas.

Silva *et al.* (2010) caracterizam três estratégias para o treinamento de uma rede neural; o treinamento supervisionado, treinamento não-supervisionado e o treinamento com reforço.

Tendo em vista a grande variabilidade e aplicações dos processos de treinamentos para redes neurais artificiais, será explorado e enfatizado apenas o processo de treinamento que será utilizado para o desenvolvimento desse trabalho que é o processo de treinamento supervisionado.

A estratégia de treinamento supervisionado consiste em se ter disponível para cada amostra de sinal de entrada as respectivas saídas desejadas que tem por finalidade “ensinar” a rede como se comportar diante dos dados que estão alimentando os neurônios de entrada.

Os pesos sinápticos e limiares são ajustados através do erro que é encontrado entre o resultado real e o resultado encontrado pela rede. O erro é então embutido novamente na rede, e os pesos são reajustados a fim de se minimizar o erro.

5.1.5 *Algoritmo de Aprendizagem backpropagation*

O processo de treinamento de redes Perceptron multicamadas (PMC) denominado *backpropagation* pode ser representado por duas fases. A primeira fase aplicada é a “propagação adiantada” (*forward*) e a segunda fase é denominada “propagação reversa” (*backward*).

Por se tratar de um processo de treinamento supervisionado, o algoritmo deve ser

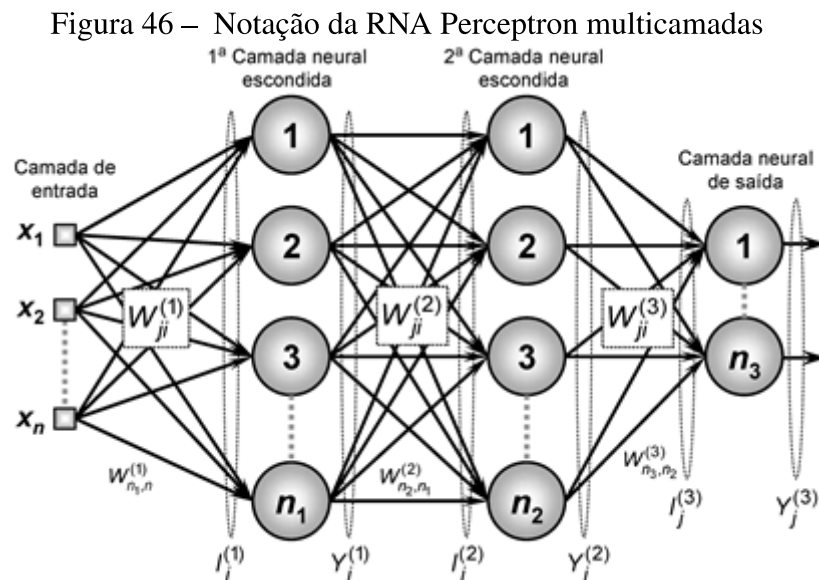
alimentado por um conjunto de dados com pares de entradas e saídas. Na fase *forward* os sinais de entrada são inseridos nas camadas de entrada da rede e são propagados através das camadas ocultas até que sejam produzidas suas respectivas saídas. Neste processo, leva-se em consideração os valores atuais dos pesos sinápticos e limiares de seus neurônios, os quais permanecerão inalterados.

O vetor de saída da rede é então comparado ao vetor de saída desejado, calculando assim o erro de saída da rede. Tais erros serão utilizados para ajustar os pesos e limiares de todos os neurônios.

Na fase seguinte, *backward*, o sinal do erro propaga-se inicialmente na camada de saída e é repassado camada por camada da rede. Esse processo de propagação de erro permite o ajuste dos pesos sinápticos e limiares de todos os neurônios da rede, assim na próxima interação o erro de saída será reduzido.

O processo sucessivo de aplicação das fases *forward* e *backward* permite que a rede esteja sempre reajustando seus pesos sinápticos e limiares de modo a minimizar o erro produzido na comparação entre a saída da rede e o resultado desejado.

O princípio de funcionamento da RNA utilizando o algoritmo *backpropagation* é ilustrado na figura a seguir.



Fonte: Silva *et al.* (2010).

A rede possui n neurônios na camada de entrada, duas camadas escondidas com n_1 e n_2 neurônios respectivamente e n_3 neurônios na camada de saída. Assume-se a seguinte terminologia dos parâmetros:

X_1, X_2, X_n são os dados de entrada da rede;

$W_{ij}^{(1)}$ Matriz de pesos sinápticos conectando os neurônios da 1ª camada neural escondida aos neurônios da camada de entrada;

$W_{ij}^{(2)}$ Matriz de pesos sinápticos conectando os neurônios da 2ª camada neural escondida aos neurônios da 1ª camada neural escondida;

$W_{ij}^{(3)}$ Matriz de pesos sinápticos conectando os neurônios da camada de saída aos neurônios da 2ª camada neural escondida.

$I_{ji}^{(1)}, I_{ji}^{(2)}, I_{ji}^{(3)}$ são os vetores cujos elementos denotam as entradas ponderadas da 1ª e 2ª camada escondida e da camada de saída respectivamente.

$Y_j^{(1)}, Y_j^{(2)}, Y_j^{(3)}$ São os vetores cujos elementos denotam as saídas das camadas escondidas 1 e 2 e da camada de saída, respectivamente.

Inicialmente as matrizes de pesos sinápticos ($W_{ji}^{(1)}, W_{ji}^{(2)}$ e $W_{ji}^{(3)}$) devem ser geradas com valores aleatórios e pequenos. As informações que chegam as camadas escondidas e a camada de saída são dadas por:

$$I_{ji}^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \quad (5.10)$$

$$I_{ji}^{(2)} = \sum_{i=0}^{n_1} W_{ji}^{(2)} \cdot Y_i^{(1)} \quad (5.11)$$

$$I_{ji}^{(3)} = \sum_{i=0}^{n_2} W_{ji}^{(3)} \cdot Y_i^{(2)} \quad (5.12)$$

$Y_j^{(1)}, Y_j^{(2)}$ e $Y_j^{(3)}$ são determinados de acordo com a função de ativação escolhida, assim, como exemplo, ao fazer-se uso da tangente hiperbólica como função de ativação obtém-se:

$$Y = g(I) \quad (5.13)$$

$$Y_j^{(1)} = tgh(I_j^{(1)}) \quad (5.14)$$

$$Y_j^{(2)} = tgh(I_j^{(2)}) \quad (5.15)$$

$$Y_j^{(3)} = tgh(I_j^{(3)}) \quad (5.16)$$

$Y_j^{(3)}$ é a saída da rede e seu valor deverá ser comparado com o valor desejado a fim de se calcular o erro e reajustar as matrizes dos pesos sinápticos, visto que trata-se de um treinamento supervisionado. Assim:

$$Erro = d_j - Y_j^{(3)} \quad (5.17)$$

Em que d_j é o resultado observado.

O ajuste dos pesos sinápticos é feito de forma reversa. Assim através do erro calculado Equação 5.17, a matriz $W_{ji}^{(3)}$ será reajustada, tal que:

$$W_{ji}^{(3)} = W_{ji}^{(3)} + \eta \cdot \delta_j^{(3)} \cdot Y_j^{(2)} \quad (5.18)$$

Em que η é a taxa de aprendizagem da rede e exprime o quão rápido o processo de treinamento da rede estará sendo conduzido para a estabilização. De acordo com Silva *et al.* (2010) normalmente adota-se valores compreendidos entre 0 e 1 para a taxa de aprendizagem.

$\delta_j^{(3)}$ é definido como o gradiente local em relação aos neurônios da camada de saída, sendo o mesmo definido por:

$$\delta_j^{(3)} = (Erro) \cdot g'(I_j^{(3)}) \quad (5.19)$$

Em que g' é a derivada da função de ativação que está sendo adotada. Seguindo o exemplo dado, em que a tangente hiperbólica foi adotada como função de ativação, a Equação 5.19 pode ser expressa da seguinte forma:

$$\delta_j^{(3)} = (Erro) \cdot sech^2(I_j^{(3)}) \quad (5.20)$$

Após a matriz $W_{ji}^{(3)}$ ser reajustada, as outras matrizes de pesos sinápticos que foram definidas aleatoriamente $W_{ji}^{(2)}$ e $W_{ji}^{(1)}$ também serão ajustadas, assim:

$$W_{ji}^{(2)} = W_{ji}^{(2)} + \eta \cdot \delta_j^{(2)} \cdot Y_j^{(1)} \quad (5.21)$$

Em que $\delta_j^{(2)}$ é dado por:

$$\delta_j^{(2)} = \sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)} g'(I_j^{(2)}) \quad (5.22)$$

$$W_{ji}^{(1)} = W_{ji}^{(1)} + \eta \cdot \delta_j^{(1)} \cdot X_i \quad (5.23)$$

Em que $\delta_j^{(1)}$ é dado por:

$$\delta_j^{(1)} = \sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)} g'(I_j^{(1)}) \quad (5.24)$$

Após o ajuste dos pesos sinápticos, os parâmetros $I_{ji}^{(1)}, I_{ji}^{(2)}$ e $I_{ji}^{(3)}$ são novamente calculados afim de se obter novos $Y_j^{(1)}, Y_j^{(2)}$ e a saída da rede que é o $Y_j^{(3)}$.

O processo é repetido usando as matrizes de pesos sinápticos ajustados até que o erro seja “aceitável” ou o número de época que foi estipulado seja alcançado.

Após o término do treinamento, pode-se então utilizar as matrizes de pesos sinápticos que foram ajustadas, para estimar a saída do sistema frente às novas amostradas que serão apresentadas em suas entradas. Essa fase chama-se de Fase de Operação.

Na fase de operação nenhum tipo de ajuste é efetuado nos parâmetros internos da rede, visto que estes já foram ajustados na fase de treinamento, assim nesta ocasião, somente a fase *forward* é processada a fim de se gerar a saída da rede.

A rede será alimentada com novos dados X_1, X_2, X_n . Os passos apresentados nas Equações 5.11, 5.12, 5.12, 5.16 e 5.16 são novamente realizados utilizando os pesos sinápticos $(W_{ji}^{(1)}, W_{ji}^{(2)} e W_{ji}^{(3)})$ ajustados. A saída da rede é dada por $Y_j^{(3)}$.

5.1.6 Modelos Híbridos de Redes Neurais

Modelos híbridos de redes neurais são abordagens que combinam diferentes tipos de redes neurais, técnicas de pré-processamento ou algoritmos de aprendizado para melhorar o desempenho e a precisão das previsões. Esses modelos são projetados para superar as limitações individuais de cada componente e explorar as vantagens de cada abordagem utilizada (LIN *et al.*, 2017).

Os modelos híbridos que combinam redes neurais com outros métodos têm sido amplamente utilizados na modelagem hidrológica, contribuindo para melhorar a precisão das previsões e a compreensão dos processos hidrológicos (MAIER; DANDY, 2000).

Na literatura, podem ser encontradas abordagens que combinam redes neurais com lógica *fuzzy* (NAYAK *et al.*, 2004; AQIL *et al.*, 2007; DIXON, 2005), algoritmos genéticos (PARASURAMAN; ELSHORBAGY, 2007; YOUNG *et al.*, 2015; SAHOO; JHA, 2017), *wavelets* (WANG; DING, 2003; FREIRE *et al.*, 2019; BELAYNEH *et al.*, 2014), e outras técnicas. Essas combinações têm sido amplamente exploradas e aplicadas em diversos contextos de modelagem hidrológica.

A integração de redes neurais com lógica *fuzzy* permite uma representação mais flexível e interpretável dos dados, combinando a capacidade de aprendizado das redes neurais com a lógica *fuzzy* para lidar com a incerteza e a imprecisão dos sistemas hidrológicos. Os algoritmos genéticos, por sua vez, são utilizados para otimizar os parâmetros das redes neurais, buscando uma melhor adequação aos dados e um desempenho mais eficiente no processo de modelagem. A incorporação de *wavelets* nas redes neurais permite a decomposição multirresolução dos dados hidrológicos, capturando informações em diferentes escalas temporais e espaciais, o que pode

melhorar a capacidade de previsão dos modelos híbridos.

A integração das redes neurais com diferentes métodos tem se mostrado eficaz pois aumenta a robustez e a precisão dos modelos, contribuindo para uma melhor compreensão e gestão dos recursos hídricos. Com o avanço contínuo na pesquisa e o desenvolvimento de novas técnicas híbridas, espera-se que as redes neurais híbridas continuem desempenhando um papel importante no aprimoramento dos modelos de previsão hidrológica e no suporte à tomada de decisões relacionadas à gestão dos recursos hídricos (FREIRE *et al.*, 2019; NAYAK *et al.*, 2004).

5.2 Metodologia

Visando desenvolver modelos fundamentados em redes neurais para a previsão das vazões nas bacias hidrográficas do Retiro Baixo, Três Marias, Sobradinho, Luiz Gonzaga, Paulo Afonso, Xingó, Banabuiú, Castanhão e Orós, foram concebidos dois modelos de previsão distintos: um modelo baseado em Rede Neural Tradicional, doravante referido como RNA, e um modelo híbrido fundamentado em *wavelets*, sugerido por Freire *et al.* (2019), denominado de WRNA.

O estudo utiliza um conjunto de dados composto por séries históricas de vazão e precipitação nas bacias hidrográficas mencionadas. As séries de precipitação consistem em médias diárias de precipitação e foram obtidas a partir da Fundação Cearense de Meteorologia e Recursos Hídricos (FUNCEME) e da Agência Nacional de Águas (ANA). As séries de vazão, por sua vez, representam vazões diárias naturalizadas e foram adquiridas do Operador Nacional do Sistema Elétrico (ONS) e da FUNCEME.

Para a precipitação das bacias do Jaguaribe, os dados abrangem o período de 1973 a 2021. Já para a precipitação das bacias do São Francisco, os dados compreendem o período de 1961 a 2021. Quanto à vazão, os dados utilizados nas bacias do Jaguaribe referem-se ao período de 1977 a 2019. Por sua vez, nas bacias do São Francisco, os registros de vazão abrangem o período de 1931 a 2015.

5.2.1 Modelos Propostos

Foram conduzidas previsões para horizontes temporais de 7, 14, 21, 28, 35 e 42 dias com o objetivo de analisar o desempenho do modelo proposto. No caso do modelo de Rede Neural Tradicionais (RNA), as previsões foram realizadas considerando os dados de vazão

e precipitação do dia atual, bem como as informações de vazão e precipitação dos 14 dias anteriores. Esse conjunto de dados foi utilizado para gerar previsões de vazões com antecedência de 7 dias. De maneira análoga, foram realizadas previsões para horizontes de 14, 21, 28, 35 e 42 dias, utilizando dados de vazão e precipitação do dia corrente e das duas semanas anteriores.


Para a implementação da Rede Neural Híbrida (WRNA), foi aplicada a transformada *wavelet* nas séries de vazão e precipitação. Esse processo de decomposição, conforme descrito no Capítulo 2.4.2, envolve a utilização de um banco de filtros que separa as componentes de alta e baixa frequência do sinal. Os coeficientes resultantes da filtragem passa-alta correspondem aos detalhes e representam as altas frequências do sinal, enquanto que a componente resultante do filtro passa-baixa corresponde aos coeficientes de aproximação, capturando as características de baixa frequência.

Desta forma, as séries de vazão e de precipitação foram submetidas a um processo de decomposição por transformada *wavelet*, utilizando as *wavelet*-mãe de *haar*, *db10*, *sym8*, *coif5* e *dmey*. As séries de vazão foram decompostas em 5 níveis de decomposição, enquanto as séries de precipitação foram decompostas em 4 níveis, para cada uma das *wavelets*-mãe mencionadas. A série bruta de vazão, bem como os coeficientes de aproximação das séries de vazão e de precipitação, gerados a cada nível de decomposição foram passados como entrada para a WRNA. Nas Figuras 47 e 48, é possível observar os processos de decomposição múltipla até o quarto nível para as precipitações diárias e até o quinto nível para as vazões diárias do reservatório de Retiro Baixo, respectivamente. Ambos os casos utilizam a *wavelet*-mãe de *Coiflet*.

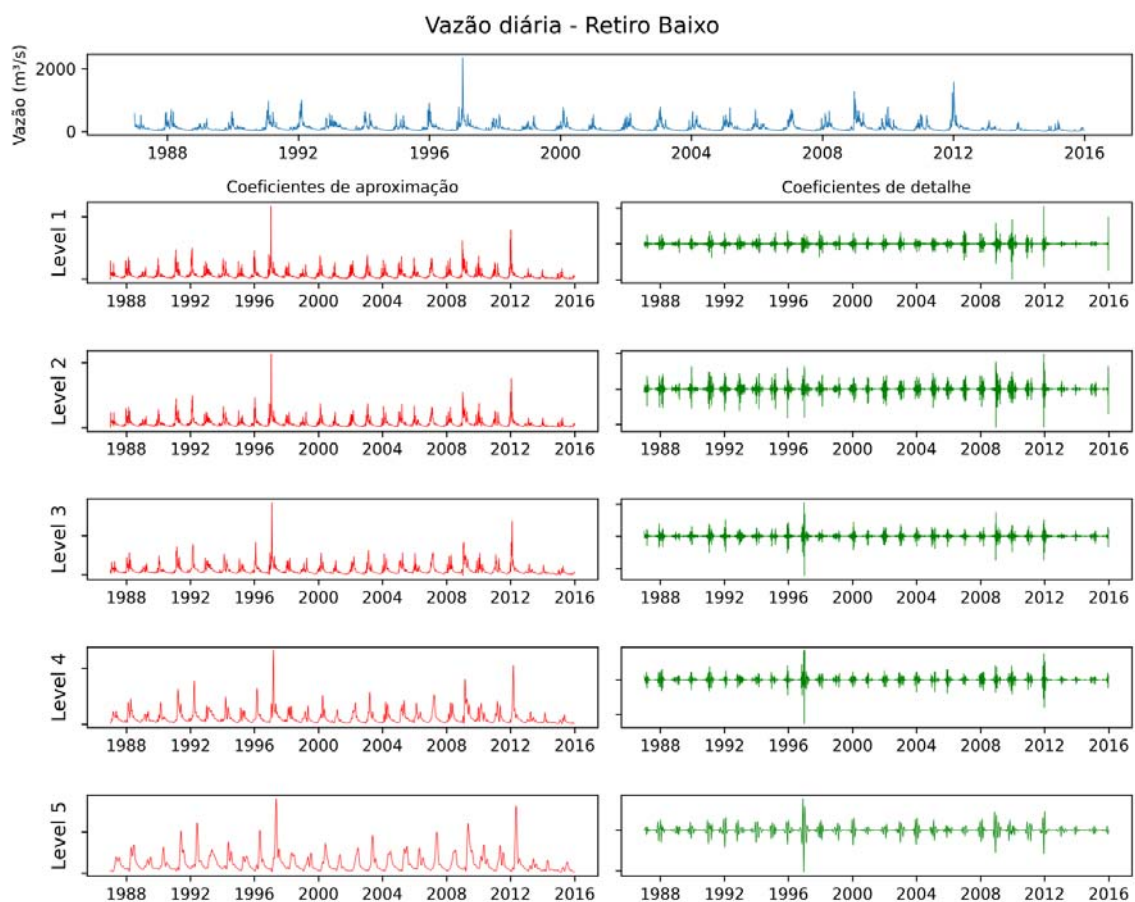
A utilização da transformada *wavelet* nos dados de entrada da rede neural tem como objetivo a identificação das distintas escalas de frequência presentes no sinal, permitindo, dessa forma, que a rede neural seja exposta aos padrões de curto e longo prazo existentes nos dados. Essa abordagem visa proporcionar uma representação mais rica e informativa dos dados, explorando a capacidade da transformada *wavelet* em decompor o sinal original em componentes de frequência relevantes.

As previsões da WRNA seguiram um procedimento semelhante ao da RNA, utilizando os dados do dia atual e das duas semanas anteriores, foram geradas previsões para os horizontes de 7, 14, 21, 28, 35 e 42 dias.

Devido à sua habilidade em capturar dependências de longo prazo, a rede neural selecionada para as duas análises propostas neste estudo é a do tipo *Long Short-Term Memory* (LSTM).

Figura 47 – Decomposição da série de precipitação - *wavelets (coif5)*

Fonte: Próprio autor.

Figura 48 – Decomposição da série de vazão - *wavelets (coif5)*

Fonte: Próprio autor.

Uma vez que não existem regras fixas para a seleção dos parâmetros de estrutura da rede, a escolha dos parâmetros foi feita com base em um processo iterativo de experimentação. Diferentes configurações foram testadas e avaliadas em termos de desempenho. Nesse sentido, a função de ativação escolhida foi a função linear, considerando seus benefícios comprovados em problemas semelhantes (WANG; DING, 2003; REIS; SILVA, 2004; CANNAS *et al.*, 2006; FREIRE *et al.*, 2019). Os demais parâmetros utilizados na arquitetura das redes são apresentados na Tabela 5.

Tabela 5 – Configurações da RNA e WRNA

Parâmetros	RNA	WRNA
Número de Neurônios da camada de entrada	2	45
Número de camadas ocultas	4	4
Nº de neurônios em cada camada oculta	200	200
Função de perda	<i>MSE</i>	<i>MSE</i>
Otimizador	Adam	Adam
Número máximo de épocas	200	200

Fonte: Elaborado pelo Autor, 2023

No processo de treinamento, o otimizador Adam foi utilizado juntamente com a função de perda *Mean Squared Error* para guiar o ajuste dos pesos da rede. Para evitar possíveis problemas de *overfitting*, foi inserida uma camada de *Dropout* após cada camada oculta. Essas camadas tem a função de desativar aleatoriamente uma fração dos neurônios durante o treinamento, o que ajuda a evitar o ajuste excessivo aos dados de treinamento.

O conjunto de dados foi dividido em dois conjuntos distintos para realizar as fases de treinamento e teste. Na divisão, optou-se por alocar 90% dos dados para a fase de treinamento, enquanto os 10% restantes foram reservados para a fase de teste. Os períodos correspondentes a cada etapa estão apresentados na Tabela 6.

Tabela 6 – Períodos analisados

Bacia	Treinamento	Teste
Retiro Baixo	01/01/1987 - 04/02/2013	05/02/2013 - 31/12/2015
Três Marias	22/02/1971 - 06/07/2011	07/07/2011 - 31/12/2015
Sobradinho	22/02/1971 - 06/07/2011	07/07/2011 - 31/12/2015
Luiz Gonzaga	22/02/1971 - 06/07/2011	07/07/2011 - 31/12/2015
Paulo Afonso	01/01/1961 - 24/11/1997	25/11/1997 - 31/12/2001
Xingó	01/01/1961 - 24/11/1997	25/11/1997 - 31/12/2001
Castanhão	28/02/1985 - 02/10/2008	03/10/2008 - 31/12/2010
Banabuiú	25/11/1996 - 30/01/2017	31/01/2017 - 30/04/2019
Orós	12/07/1993 - 30/01/2017	31/01/2017 - 30/04/2019

Fonte: Elaborado pelo Autor, 2023

É relevante destacar que a heterogeneidade dos períodos analisados decorre do processo de pré-processamento dos dados. Nesse processo, foram adotadas medidas para lidar com os dados faltantes. Desta forma, durante o pré-processamento foi removido períodos com dados faltantes, visando assegurar que as séries temporais utilizadas nas fases de treinamento e teste sejam contínuas e livres de lacunas. Além disso, destaca-se a necessidade de se ter períodos correspondentes nos conjuntos de dados de vazão e precipitação como limitador para a homogeneidade das séries de cada bacia.

Para garantir que todas as variáveis de entrada estejam na mesma escala e assim melhorar o desempenho da rede neural durante a fase de treinamento optou-se por realizar a normalização dos dados utilizados. O processo de normalização foi realizado da seguinte forma:

$$X^* = \frac{X_o - X_{MIN}}{X_{MAX} - X_{MIN}} \quad (5.25)$$

Nessa equação, X^* representa a variável normalizada, X_o é a variável a ser normalizada, X_{MIN} corresponde ao valor mínimo da variável a ser normalizada e X_{MAX} é o valor máximo da variável a ser normalizada.

Inicialmente, a normalização foi aplicada ao conjunto de treinamento e, posteriormente, estendida ao conjunto de teste, mantendo-se o mesmo fator de normalização em ambos os conjuntos.

Da mesma forma, os valores da camada de saída da rede foram recuperados utilizando a equação inversa:

$$X = Y \cdot (X_{MAX} - X_{MIN}) + X_{MIN} \quad (5.26)$$

em que, X é o valor desnormalizado e Y é a saída da rede neural.

5.2.2 Avaliação das previsões

A avaliação foi conduzida de forma mensal, comparando os valores previstos com os valores observados. Após a geração das previsões pela rede neural durante a fase de testes, foram selecionadas apenas as previsões correspondentes ao mês de janeiro. Essas previsões foram então comparadas com os valores observados de vazão para o mesmo período e utilizando índices estatísticos o desempenho do modelo foi avaliado exclusivamente para o mês de janeiro. Esse processo foi repetido para os demais meses.

Essa abordagem permite também avaliar o desempenho do modelo em diferentes condições hidrológicas e obter *insights* sobre sua eficácia na previsão de eventos específicos em determinados meses, proporcionando uma compreensão mais aprofundada dos modelos de previsão desenvolvidos.

Na análise do modelo de previsão, foram utilizados três índices estatísticos, os quais estão descritos no Tópico 3.3.2 deste trabalho. Para medir o grau de correlação entre as variáveis previstas e observadas, foi utilizado o coeficiente de correlação de Pearson (r). O índice de eficiência de *Nash-Sutcliffe* (*Nash*) foi empregado para determinar a proporção da variância observada que é explicada pelo modelo. Além disso, a raiz quadrada do erro médio (*RMSE*) foi utilizada como uma estimativa média dos erros.

Também foi realizado o cálculo do erro residual, representado pela Equação 5.27, o qual corresponde à diferença entre o valor observado (Q_o) e o valor previsto pelo modelo (Q_{mod}).

$$\varepsilon = Q_o - Q_{mod} \quad (5.27)$$

É importante destacar que, em contraste com os modelos híbridos de RNA que empregam a transformada wavelet, a RNA proposta nesta pesquisa adota uma arquitetura distinta, conhecida como *Long Short-Term Memory* (*LSTM*). Além disso, um aspecto relevante é o enfoque na utilização de múltiplas *wavelets*-mãe, ao invés de empregar apenas uma por vez. Vale também destacar que o método de avaliação também difere do apresentado em Freire *et al.* (2019). Enquanto o modelo anterior avalia a precisão usando todo o conjunto de previsão, neste estudo optamos por realizar a avaliação mensalmente. Essa abordagem traz vantagens como a capacidade de identificar padrões sazonais e variações intra-mensais, permitindo uma análise mais precisa.

Todas as análises e simulações descritas neste capítulo foram realizadas utilizando a linguagem de programação *Python*. Na implementação das redes neurais, foi utilizada a biblioteca *Keras*. Para as análises baseadas em *wavelets*, utilizou-se a biblioteca *PyWavelets*, que fornece um conjunto abrangente de funções para a transformação e análise de sinais utilizando *wavelets*.

5.3 Resultados

5.3.1 *Redes Neurais Tradicionais*

Os resultados apresentados nas Tabelas 7 a 13 e nas Figuras 84 a 110 correspondem aos resultados obtidos por meio das simulações utilizando a abordagem da rede neural tradicional na fase de testes. As tabelas fornecem uma análise detalhada dos principais índices estatísticos aplicados aos diferentes horizontes de previsão em cada bacia hidrográfica. As colunas destacadas correspondem aos meses em que historicamente são observados os maiores índices pluviométricos na região. As figuras apresentam o ajuste dos dados previstos em relação aos valores observados de vazão e informações sobre os erros residuais das previsões. Adicionalmente, as figuras também ilustram a distribuição dos resíduos, o que auxilia na compreensão da natureza e magnitude dos erros do modelo.

Nesta seção, são apresentadas exclusivamente as tabelas contendo os índices estatísticos obtidos. Os gráficos contendo mais informações sobre as previsões, estão disponíveis no Anexo B deste trabalho.

De modo geral a rede neural apresentou variações significativas, tanto em relação ao horizonte de previsão quanto ao mês considerado. Essa análise revela a influência de diferentes fatores e condições hidrológicas nos resultados obtidos.

Nas bacias de Retiro Baixo, Três Marias e Sobradinho os resultados da análise revelam que as previsões de 7 dias apresentaram correlações superiores a 0.6 na maior parte dos meses. A explicação para esta correlação significativa está relacionada à utilização de dados dos 14 dias anteriores para prever a vazão com 7 dias de antecedência. Nesse contexto, a alta correlação entre os preditores e previsores foi observada pela rede neural, refletindo-se nas previsões. Conforme o horizonte de previsão se estende para 14, 21, 28, 35 e 42 dias, há uma diminuição nas correlações entre preditores e previsores, o que também é refletido nas previsões.

Observa-se que para estas bacias, o modelo apresentou um desempenho relativamente bom durante os meses de junho, julho e agosto. Esses meses são caracterizados como período de estiagem na região, quando os índices pluviométricos tendem a ser menores, o que conseqüentemente afeta as vazões dos rios, desta forma os resultados indicam que o modelo possui uma habilidade em capturar as tendências hidrológicas durante esses períodos de menor disponibilidade de água.

No entanto, ao analisar os índices de desempenho do modelo para essas bacias,

nota-se um desempenho geral desfavorável. Apesar de o modelo capturar de forma satisfatória o comportamento geral das séries de vazões (Figuras 84 a 91), ele tende a superestimar as vazões. Especialmente ao avaliar o *Nash*, observa-se que predominam valores negativos. Esses resultados indicam que o modelo não está conseguindo capturar corretamente a variabilidade e os padrões das séries de vazões observadas.

As previsões nas bacias de Luis Gonzaga, Paulo Afonso e Xingó apresentaram desempenho abaixo das três bacias que foram anteriormente apresentadas. Em relação ao *Nash-Sutcliffe*, foi encontrado valores negativos em vários meses e períodos de previsão. Indicando que o modelo de previsão apresenta um desempenho inferior em comparação com uma simples média dos dados observados e não captura adequadamente a variabilidade e os padrões das séries de vazões.

Nos meses de março e maio, foram observadas correlações significativas (0,69) nas previsões de 7 e 14 dias na bacia de Luis Gonzaga. No entanto, nos demais meses, as correlações foram abaixo de 0,3 ou negativas. Para a bacia de Paulo Afonso, as melhores correlações foram encontradas nas previsões de 7 a 28 dias durante o mês de setembro. Já para a bacia de Xingó, as melhores correlações foram observadas no mês de junho.

Os valores do *RMSE* mostraram consistentemente um nível elevado em todos os períodos e meses de previsão (Tabela 10 a 12), indicando uma diferença significativa entre as previsões e os valores observados. A dificuldade em capturar a variabilidade das vazões é particularmente notável na bacia de Paulo Afonso (Figura 96). Além disso, observou-se uma tendência dos resíduos nas bacias de Paulo Afonso e Luiz Gonzaga em direção a valores maiores do que zero, enquanto na bacia do Xingó esses resíduos apresentaram uma tendência para valores negativos. Essas tendências sugerem a presença de um viés sistemático ou de um padrão não detectado pelo modelo.

Os resultados obtidos para as bacias do alto e médio Jaguaribe (Tabela 13, Figuras 102 a 109) foram semelhantes aos das bacias do baixo São Francisco. No entanto, é importante ressaltar a presença de longos períodos de ausência de dados nas séries do Castanhão, Banabuiú e Orós. Essas ausências de dados podem ter um impacto significativo na qualidade das previsões, uma vez que a falta de informações dificulta a modelagem e a captura adequada das características hidrológicas dessas bacias. Para todo período analisado, nas bacias do Orós e Banabuiú as correlações e o *Nash-Sutcliffe* foram inconsistentes, portanto a tabela contendo os índices estatísticos para essas bacias são apresentadas apenas no Anexo B deste trabalho.

Tabela 7 – Previsões (RNA) - Retiro Baixo

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.804	0.21	0.632	0.615	0.634	0.901	0.474	0.613	0.612	0.537	0.617	0.346
	NASH	-4.608	-2.072	-0.137	-0.076	-3.02	0.655	-0.866	-2.44	-14.634	-0.975	-0.54	0.012
	RMSE	108.528	102.593	45.851	34.84	18.184	10.665	10.218	16.08	26.158	22.554	28.051	60.929
14 dias	r	0.361	0.606	0.185	0.509	0.674	0.732	0.786	0.554	-0.274	0.397	0.439	0.257
	NASH	-15.565	-3.264	-1.627	-0.737	-10.676	0.449	0.585	-0.529	-14.646	-0.803	-2.776	-1.389
	RMSE	186.527	121.849	69.69	44.281	30.988	13.472	4.82	10.719	26.169	21.549	43.923	94.739
21 dias	r	-0.12	0.114	0.045	0.394	0.494	0.641	0.658	0.634	-0.286	-0.048	0.4	0.018
	NASH	-29.798	-5.607	-3.168	-1.236	-16.125	0.339	0.167	0.36	-2.936	-1.794	-1.384	-0.759
	RMSE	254.335	159.844	87.786	50.239	37.529	14.756	6.828	6.934	13.125	26.827	34.897	81.298
28 dias	r	-0.113	-0.358	0.358	0.329	0.681	0.598	0.69	0.151	-0.285	-0.051	0.569	0.12
	NASH	-17.203	-33.316	-0.298	-1.047	-15.235	0.175	-1.235	-1.53	-8.508	-4.083	-3.374	-0.211
	RMSE	195.533	152.287	88.136	48.06	36.541	16.489	11.182	13.79	20.4	36.186	47.27	67.447
35 dias	r	-0.403	-0.419	-0.424	0.353	0.549	0.781	0.61	0.16	-0.191	-0.163	0.506	0.017
	NASH	-25.868	-58.107	-0.751	-1.257	-21.764	0.414	-0.198	-0.8	-5.882	-5.067	-5.13	-0.976
	RMSE	237.554	199.863	105.574	50.468	43.27	13.898	8.185	11.63	17.355	39.533	55.964	86.155
42 dias	r	-0.428	0.019	0.247	0.558	0.445	0.557	0.442	0.489	-0.297	-0.079	0.523	0.143
	NASH	-37.32	-68.269	-0.353	-1.176	-23.835	-0.311	-1.305	0.213	-2.326	-3.23	-5.565	-1.962
	RMSE	283.699	216.363	96.766	49.554	45.194	20.783	11.357	7.692	12.065	33.009	57.914	105.477

Fonte: Elaborado pelo Autor, 2023

Tabela 8 – Previsões (RNA) - Três Marias

Previsão	Índices	Jan	Feb	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.915	0.796	0.74	0.884	0.766	0.828	0.948	0.865	0.612	0.549	0.486	0.768
	NASH	0.726	0.521	0.474	0.286	0.236	-0.096	0.894	0.728	-0.181	-0.019	0.154	0.555
	RMSE	466.243	348.806	184.263	149.619	79.59	114.451	22.245	29.597	46.293	83.448	159.883	306.766
14 dias	r	0.775	0.683	0.158	0.773	0.541	0.555	0.881	0.879	0.78	0.33	0.511	0.436
	NASH	0.449	-0.119	-0.717	-0.152	-1.288	0.148	0.725	0.734	0.024	-0.71	0.117	0.182
	RMSE	661.01	533.177	332.791	190.048	137.756	100.934	34.491	29.26	42.083	108.106	163.328	415.95
21 dias	r	0.405	0.694	0.035	0.463	0.612	0.699	0.761	0.912	0.623	0.354	0.454	0.32
	NASH	-0.089	-0.12	-7.992	-0.77	-0.185	0.3	0.471	0.297	-1.728	-1.805	-0.267	-0.128
	RMSE	929.451	533.467	761.64	235.533	99.13	91.467	45.709	47.587	70.352	138.444	195.662	488.567
28 dias	r	0.49	0.614	-0.228	0.41	0.365	0.47	0.682	0.839	0.74	0.275	0.428	0.189
	NASH	0.045	-1.509	-3.721	-1.361	-4.445	-0.114	0.274	0.613	0.313	-0.718	-0.106	0.018
	RMSE	870.233	798.337	551.886	272.041	212.491	115.387	58.499	34.617	35.316	108.336	182.829	455.777
35 dias	r	0.192	0.232	-0.1	0.501	0.443	0.563	0.539	0.893	0.526	0.428	0.619	0.199
	NASH	-0.082	-1.39	-4.033	-1.293	-4.851	-0.11	-0.177	0.343	-0.751	-0.898	0.028	0.027
	RMSE	926.168	779.275	569.833	268.084	220.267	115.199	74.512	44.252	56.374	113.898	171.447	453.672
42 dias	r	-0.006	0.206	0.068	0.467	0.685	0.718	0.807	0.856	0.642	0.389	0.633	0.195
	NASH	-0.198	-1.21	-7.843	-5.988	-0.283	0.359	0.447	0.312	-0.642	-0.5	-0.031	-0.659
	RMSE	974.625	749.233	755.287	467.991	103.135	87.564	51.064	43.177	54.59	101.227	176.523	592.411

Fonte: Elaborado pelo Autor, 2023

Tabela 9 – Previsões (RNA) - Sobradinho

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.918	0.837	0.758	0.8	0.876	0.749	0.786	0.774	0.792	0.962	0.832	0.743
	NASH	0.842	0.66	0.325	0.619	-0.34	0.484	-0.353	-0.276	0.139	0.892	0.55	0.548
	RMSE	556.668	775.509	388.047	293.883	244.668	96.004	92.28	76.28	102.87	80.586	356.472	656.557
14 dias	r	0.785	0.701	0.614	0.536	0.852	0.606	0.554	0.783	0.634	0.901	0.85	0.544
	NASH	0.491	0.419	-0.016	-0.111	-0.701	-0.119	-1.827	-0.548	0.148	0.574	0.674	0.283
	RMSE	998.572	1013.395	476.13	501.579	275.672	141.373	131.94	84.001	102.291	160.368	303.687	827.195
21 dias	r	0.535	0.681	0.516	0.097	0.729	0.182	0.392	0.595	0.708	0.725	0.576	0.399
	NASH	0.269	0.374	-0.401	-0.729	-1.165	-0.428	-0.871	0.101	0.345	0.236	0.291	0.137
	RMSE	1196.872	1051.937	559.335	625.868	311.001	159.706	99.644	64.039	89.705	214.67	447.669	907.655
28 dias	r	0.086	0.737	0.528	0.535	0.27	0.037	0.178	0.268	0.436	0.649	0.205	0.46
	NASH	-0.232	0.487	-0.869	-0.484	-2.089	-1.075	-2.073	-1.472	0.187	0.201	-0.031	0.149
	RMSE	1554.003	951.828	645.947	579.912	371.528	192.477	116.76	97.57	99.959	219.582	539.883	901.187
35 dias	r	-0.197	0.495	0.177	0.237	0.18	0.05	-0.11	0.421	0.667	0.714	0.133	0.159
	NASH	-0.324	0.219	-6.673	-0.082	-2.714	-0.756	-0.215	0.093	-0.42	-0.376	-0.004	-0.221
	RMSE	1610.987	1174.83	1308.758	495.199	407.387	177.067	73.434	59.872	132.078	288.143	532.617	1079.365
42 dias	r	0.07	0.377	-0.104	0.188	0.282	-0.222	-0.538	0.028	-0.064	-0.136	-0.21	0.17
	NASH	-0.361	-0.292	-6.927	-7.208	-5.685	-7.534	-2.017	-2.876	-6.814	-7.587	-2.471	0.006
	RMSE	1633.325	1511.446	1330.262	1363.595	546.539	390.356	115.693	125.383	309.868	719.71	990.436	974.014

Fonte: Elaborado pelo Autor, 2023

Tabela 10 – Previsões (RNA) - Luis Gonzaga

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	-0.475	0.249	0.53	-0.415	0.696	0.463	-0.171	0.332	-0.131	-0.155	-0.178	0.2
	NASH	-0.524	-0.046	0.255	-0.593	0.138	-0.248	-0.609	-0.732	-1.235	-1.006	-0.684	-0.63
	RMSE	219.992	140.493	89.117	144.655	82.473	32.875	29.394	35.819	35.001	43.724	56.663	82.433
14 dias	r	0.035	0.368	0.699	-0.066	0.695	-0.161	0.253	-0.522	-0.25	-0.163	-0.198	-0.102
	NASH	-0.306	-0.623	0.356	-0.732	0.119	-2.781	-4.845	-4.005	-4.492	-2.557	-1.116	-0.949
	RMSE	203.671	174.962	82.859	150.836	83.384	57.224	42.754	60.895	54.869	58.217	63.516	90.161
21 dias	r	-0.151	-0.117	0.18	0.246	0.49	0.211	-0.165	-0.193	-0.418	-0.4	-0.313	0.117
	NASH	-0.64	-1.752	-0.478	-0.817	-0.268	-6.531	-15.047	-7.22	-8.948	-3.299	-0.565	-0.39
	RMSE	228.205	227.857	125.503	154.46	100.035	80.764	71.733	78.042	73.849	64.002	54.637	76.128
28 dias	r	-0.387	-0.376	-0.407	0.25	0.148	0.272	-0.174	-0.274	-0.326	-0.444	-0.248	0.6
	NASH	-0.576	-1.259	-0.3	-0.028	-0.041	-0.751	-1.303	-4.081	-6.209	-3.506	-0.617	0.348
	RMSE	223.749	206.432	117.697	116.179	90.641	38.946	67.536	62.71	62.866	65.529	55.521	52.134
35 dias	r	-0.341	-0.42	0.102	0.225	0.141	0.329	0.016	-0.39	-0.367	-0.259	-0.108	0.489
	NASH	-0.459	-1.314	-0.036	-0.071	-0.098	-0.35	-1.157	-4.249	-5.21	-2.657	-0.57	0.173
	RMSE	215.274	208.909	105.087	118.611	93.064	34.193	65.364	63.91	58.345	59.03	54.721	58.713
42 dias	r	-0.446	-0.386	0.481	0.177	0.239	-0.007	-0.108	-0.576	-0.444	-0.473	-0.197	0.36
	NASH	-0.872	-0.69	-0.063	-0.029	-0.008	-0.708	-1.067	-4.408	-6.435	-4.347	-1.543	-0.225
	RMSE	243.844	178.563	106.458	116.28	89.18	38.464	63.973	66.263	63.841	71.38	69.632	71.477

Fonte: Elaborado pelo Autor, 2023

Tabela 11 – Previsões (RNA) - Paulo Afonso

Previsão	Índices	Jan	Feb	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	-0.224	-0.238	-0.164	0.294	-0.286	0.022	0.002	-0.246	0.355	0.054	0.058	-0.219
	NASH	-1.58	-0.979	-0.634	-0.708	-0.983	-0.815	-3.931	-0.841	-1.333	-0.266	-8.455	-0.625
	RMSE	119.072	91.084	164.023	161.871	70.526	32.07	19.122	52.782	18.735	72.468	18.301	103.659
14 dias	r	-0.039	-0.183	-0.011	0.147	-0.096	0.177	0.509	-0.094	0.452	0.195	0.365	-0.102
	NASH	-1.486	-1.266	-0.76	-0.843	-1.382	-2.086	-12.387	-1.533	-4.641	-0.372	-13.84	-0.655
	RMSE	116.877	97.463	170.248	168.132	77.289	41.817	31.506	61.902	29.128	75.461	22.928	106.204
21 dias	r	0.409	0.114	0.101	0.504	0.231	0.007	0.277	0.074	0.542	0.063	0.026	-0.264
	NASH	-1.598	-1.253	-0.784	-0.859	-1.365	-2.194	-11.795	-1.47	-4.582	-0.433	-16.589	-0.745
	RMSE	119.473	97.183	171.382	168.898	77.008	42.544	30.802	61.13	28.976	77.118	24.962	110.886
28 dias	r	-0.057	0.439	0.368	0.368	0.351	0.181	-0.093	-0.02	0.48	0.339	-0.012	-0.056
	NASH	-1.464	-1.433	-0.895	-1.019	-1.714	-4.21	-25.03	-2.33	-8.717	-0.497	-22.635	-0.739
	RMSE	116.358	100.991	176.67	175.998	82.498	54.335	43.933	70.979	38.232	78.81	28.935	112.97
35 dias	r	-0.064	-0.175	0.244	-0.121	-0.074	0.027	-0.086	-0.131	-0.625	0.203	0.169	-0.316
	NASH	-1.391	-0.87	-0.556	-0.672	-0.718	-0.379	-1.2	-0.484	-0.415	-0.137	-1.367	-0.489
	RMSE	114.616	88.534	160.053	160.179	65.641	27.954	12.772	47.39	14.592	68.686	9.157	106.885
42 dias	r	0.128	-0.425	-0.032	0.406	0.143	0.212	0.041	-0.245	0.091	0.47	0.022	0.093
	NASH	-1.06	-1.026	-0.627	-0.742	-0.881	-0.661	-2.772	-0.68	-0.84	-0.189	-3.568	-1.035
	RMSE	126.006	92.153	163.69	163.492	68.691	30.678	16.723	50.413	16.638	70.252	12.722	94.611

Fonte: Elaborado pelo Autor, 2023

Tabela 12 – Previsões (RNA) - Xingó

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	-0.174	-0.045	-0.064	-0.094	0.146	0.232	-0.103	0.102	-0.123	-0.05	-0.085	0.024
	NASH	-0.262	-0.193	-0.434	-0.136	-1.109	-9.284	-89.394	-0.715	-0.18	-0.345	-2.572	-0.065
	RMSE	196.0	169.163	124.981	209.897	72.407	70.242	62.71	54.977	83.319	83.343	93.881	165.838
14 dias	r	-0.115	-0.022	0.122	0.143	0.391	0.451	0.368	-0.38	-0.331	0.025	-0.144	0.233
	NASH	-0.062	-0.032	-0.21	-0.028	-1.171	-10.716	-96.828	-0.907	-0.143	-0.245	-0.987	0.029
	RMSE	179.835	157.347	114.821	199.686	73.472	74.97	65.238	57.967	81.986	80.209	70.023	160.731
21 dias	r	0.368	-0.01	-0.013	-0.025	0.377	0.198	0.412	-0.499	-0.339	0.112	-0.101	0.275
	NASH	0.05	-0.144	-0.321	-0.095	-1.396	-9.122	-109.187	-1.161	-0.154	-0.259	-1.265	0.026
	RMSE	170.083	165.666	119.965	206.079	77.189	69.685	69.236	61.719	82.376	80.651	74.756	163.48
28 dias	r	0.262	-0.001	0.087	0.293	0.427	0.18	0.078	-0.5	-0.436	-0.061	0.228	-0.214
	NASH	0.038	-0.049	-0.306	-0.003	-1.708	-8.954	-91.588	-0.817	-0.114	-0.215	-0.991	-0.04
	RMSE	171.195	158.653	119.277	197.213	82.049	69.106	63.467	56.582	80.965	79.237	70.096	171.955
35 dias	r	-0.131	0.321	0.423	0.339	0.136	0.383	0.102	-0.271	-0.337	0.356	-0.164	0.238
	NASH	-0.055	0.074	-0.262	0.03	-1.56	-9.073	-100.702	-0.915	-0.16	-0.081	-1.049	0.025
	RMSE	179.235	149.025	117.251	193.964	79.78	69.516	66.517	58.094	82.614	74.719	71.111	169.638
42 dias	r	-0.229	0.199	0.348	0.547	0.364	0.365	-0.043	-0.362	-0.317	0.629	0.326	0.327
	NASH	-0.068	0.034	-0.514	0.066	-2.3	-11.465	-92.101	-0.547	-0.065	-0.031	-1.008	0.07
	RMSE	126.916	152.217	128.403	190.287	90.58	77.332	63.642	52.223	79.142	72.969	70.401	81.511

Fonte: Elaborado pelo Autor, 2023

Tabela 13 – Previsões (RNA) - Castanhão

Previsão	Índices	Jan	Feb	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.512	-0.798	0.162	0.537	0.772	0.957	0.581	0.554	0.025	0.5	0.845	0.888
	NASH	-65.83	-267.063	-30.844	0.285	0.306	0.905	0.136	-4.364	-12.893	0.124	-2.807	-11.777
	RMSE	39.869	51.359	58.086	151.008	319.981	21.024	17.891	16.98	14.325	19.345	12.88	14.291
14 dias	r	0.3	-0.484	0.323	0.584	0.724	0.903	0.601	0.702	0.243	0.15	0.057	0.432
	NASH	-22.343	-67.261	-15.787	0.271	0.136	0.771	0.257	0.225	-3.008	0.022	-2.608	-9.738
	RMSE	23.563	25.917	42.174	152.414	356.963	32.634	16.593	6.454	7.695	21.216	12.539	13.101
21 dias	r	0.136	0.522	-0.013	0.297	0.361	0.928	0.694	0.448	0.589	-0.203	0.03	-0.031
	NASH	-8.795	-429.707	-36.245	-0.032	-0.236	0.858	0.427	-1.211	-3.527	-0.082	-2.862	-1.459
	RMSE	15.263	65.101	62.819	181.419	426.992	25.674	14.57	10.903	8.178	23.201	12.972	6.27
28 dias	r	-0.337	-0.013	0.61	-0.484	-0.043	0.898	0.483	0.136	0.401	-0.257	0.085	-0.029
	NASH	-3.299	-850.627	-67.633	-0.286	-0.46	0.785	0.158	-1.978	-4.283	-0.062	-3.033	-3.528
	RMSE	10.112	91.543	85.275	202.479	464.002	31.615	17.664	12.653	8.834	23.949	13.257	8.507
35 dias	r	0.642	-0.023	0.491	-0.521	-0.566	0.927	0.826	0.318	0.615	0.037	0.57	0.128
	NASH	-8.413	-559.493	-122.411	-0.131	-0.539	0.399	-2.259	-15.973	-48.339	-0.626	-26.025	-27.295
	RMSE	14.963	74.265	114.349	189.924	476.386	52.879	34.743	30.206	26.996	25.67	18.467	21.266
42 dias	r	-0.196	-0.469	0.764	-0.153	-0.47	0.843	0.632	0.164	0.128	0.503	-0.128	0.211
	NASH	-5.437	-194.285	-76.229	-0.078	-0.646	0.562	0.0	-2.288	-7.818	0.217	-8.208	-5.929
	RMSE	12.373	43.836	90.458	185.404	492.777	45.161	19.24	13.294	11.413	17.821	10.815	10.523

Fonte: Elaborado pelo Autor, 2023

5.3.2 *Redes Neurais - Wavelets*

As Tabelas 14 a 20 fornecem os resultados, separados por mês, dos coeficientes de correlação de Pearson, do índice de eficiência de *Nash-Sutcliffe* e da raiz quadrada do erro médio para as previsões realizadas pela WRNA na fase de testes nas bacias hidrográficas investigadas. As colunas destacadas correspondem aos meses em que historicamente são observados os maiores índices pluviométricos na região. As Figuras 49 a 66 apresentam os gráficos que demonstram o ajuste das previsões em relação aos dados observados, os resíduos das previsões e a distribuição dos resíduos das previsões realizadas pela WRNA.

Nesta seção, são apresentados apenas os gráficos contendo as previsões para os horizontes de 7, 14, 21 e 28 dias. Os gráficos para os demais períodos de previsão podem ser consultados no Anexo C deste trabalho.

Constata-se que as redes neurais híbridas demonstraram resultados superiores às simulações realizadas pela rede neural tradicional em todas as bacias hidrográficas avaliadas. Os índices estatísticos obtidos foram significativamente melhores, e as simulações foram capazes de capturar de forma mais precisa as tendências dos dados observados.

Na bacia de Retiro Baixo (Tabela 14), observou-se uma variação das correlações para as previsões de 7 e 14 dias, oscilando entre 0,99 e 0,40. O índice *Nash* manteve-se próximo a 0,8 na maioria dos meses. Nas previsões de 21 e 28 dias, as correlações permaneceram próximas a 0,9, mas o índice *Nash* apresentou algumas variações. Especificamente, nas previsões de 21 dias, os meses de maio, julho e outubro exibiram valores inconsistentes, enquanto nas previsões de 28 dias, os meses de fevereiro, julho e setembro revelaram valores negativos ou próximos de zero.

Nas previsões de 35 e 42 dias, foram observadas correlações significativas nos meses de janeiro, abril, maio, junho, julho, agosto, novembro e dezembro. O *Nash* apresentou resultados consistentes apenas nos meses de março, abril, junho e novembro (35 dias). Em geral, para todos os horizontes de previsão, o *RMSE* foi consideravelmente menor em comparação com as previsões realizadas pela rede neural tradicional. Destaca-se especialmente o desempenho no mês de janeiro, em que a RNA apresentou um *RMSE* de 108,53 para previsões de 7 dias e de 283,7 para previsões de 42 dias. Por outro lado, a WRNA obteve *RMSE* de 9,29 e 71,7, respectivamente, para o mesmo período.

Nas Figuras 49, 50 e 111, é possível visualizar o ajuste das previsões em relação às vazões observadas na bacia de Retiro Baixo. É importante notar que os maiores erros ocorrem

nos períodos em que as vazões são mais altas. No entanto, ao analisar a distribuição dos resíduos, verifica-se que eles seguem uma distribuição normal em torno de zero, o que indica uma adequada representação do modelo em relação aos dados observados.

O desempenho da WRNA na bacia de Três Marias é apresentado na Tabela 15 e nas Figuras 51, 52 e 112. É importante destacar que a correlação entre as previsões e as vazões observadas foi consistentemente superior a 0,9 em todos os meses e horizontes de previsão, com apenas algumas exceções pontuais. Esses resultados indicam um alto grau de concordância entre as previsões geradas pelo modelo e os dados reais, evidenciando a eficácia da WRNA na captura dos padrões de vazão na bacia de Três Marias.

Com relação ao índice *Nash*, os valores foram muito próximos de 1 nas previsões de 7 a 35 dias, com exceção apenas no mês de setembro. Em 83% das previsões realizadas, o *Nash* foi superior a 0,8, indicando uma boa capacidade do modelo em reproduzir as variações das vazões observadas. No que diz respeito ao *RMSE*, observou-se que os maiores valores ocorreram nos meses de janeiro e dezembro, coincidindo com o período em que as vazões são naturalmente mais elevadas nessa bacia. Essa maior variabilidade nas vazões contribuiu para um aumento nos erros das previsões.

Entre as bacias estudadas, as previsões realizadas para a bacia de Sobradinho foi a que apresentou o melhor desempenho, conforme evidenciado na Tabela 16 e ilustrado nas Figuras 53, 54 e 113. Para a maioria dos meses e horizontes de previsão, foram observadas correlações e valores de *Nash* superiores a 0,9. Houve uma redução nos valores de *Nash* apenas nos meses de maio a julho, especificamente nas previsões de 35 e 42 dias. Apesar disso, considerando o desempenho geral, a WRNA demonstrou uma eficiência significativa na previsão das vazões para esta bacia.

As simulações realizadas pela RNA para as bacias do sub-médio e baixo São Francisco foram consideradas ineficientes, uma vez que, para a maioria dos horizontes de previsão, o índice *Nash* apresentou valores próximos de zero ou negativos e as correlações foram baixas. Ao analisar as previsões realizadas pela WRNA, pode-se observar um ganho significativo desse modelo em comparação com as RNAs tradicionais. Esse resultado indica uma melhora substancial na capacidade de previsão das vazões quando se utiliza a abordagem híbrida.

Para bacia de Luiz Gonzaga (Tabela 17, Figuras 55 e 56) o modelo demonstrou um desempenho superior nos primeiros seis meses de análise. Durante esse período, todas as previsões apresentaram correlações e índice *Nash* elevados, com poucas exceções pontuais. No

entanto, ao adentrar no segundo semestre, houve uma queda consistente tanto nas correlações quanto no índice *Nash*. É interessante destacar que as previsões para 28 dias mostraram-se mais acuradas em comparação com as de 14 e 21 dias.

É importante ressaltar a notável capacidade da WRNA em capturar os picos de vazão presentes nesta série, o que não foi observado na RNA. Isso indica que o modelo é capaz de identificar e reproduzir momentos de maior intensidade das vazões observadas. Esse aspecto é crucial, uma vez que os picos de vazão muitas vezes representam eventos hidrológicos de grande relevância, como cheias e períodos de enchentes.

Para a bacia de Paulo Afonso (Tabela 18, Figuras 57 e 58) os primeiros quatro meses foram destacados como o período de melhor desempenho da WRNA. Durante esse período, observou-se uma correlação positiva e significativas e o (*Nash*) apresentou valores mais expressivos, especialmente para os horizontes de previsão de 7 a 28 dias. Para as previsões de 35 e 42 dias, verificou-se uma diminuição na qualidade das estimativas, indicando uma menor precisão nas previsões de longo prazo.

Identificaram-se limitações significativas do modelo nos meses de setembro e novembro, nos quais o desempenho geral foi insatisfatório. Esses meses específicos foram caracterizados por correlações e *Nash* insatisfatórios para todos os horizontes de previsão avaliados.

A Tabela 19, juntamente com as Figuras 59 e 60, apresentam os resultados das simulações da WRNA para a bacia de Xingó. As previsões realizadas pela WRNA apresentaram melhor desempenho nos horizontes de 7 a 28 dias. No entanto, foram identificadas limitações significativas nos meses de maio e junho, nos quais o índice *Nash* apresentou valores negativos para todos os horizontes de previsão avaliados. Para horizonte de 42 dias, constatou-se que os resultados mais acurados foram obtidos nos meses de abril, agosto e setembro. Pode-se também perceber que os maiores valores de *RMSE* foram observados nos primeiros quatro meses, coincidindo com o período onde as precipitações são mais expressivas nesta bacia.

Comparando as simulações da WRNA com as RNAs, observou-se que a WRNA consegue capturar com mais precisão os picos da série hidrológica, fato este que não foi observado na RNA. Por fim, cabe ressaltar que a distribuição dos resíduos das simulações da WRNA demonstrou uma tendência à normalidade, o que também não foi observado nas simulações realizadas pela RNA.

Para as simulações das bacias do Jaguaribe, novamente os extensos períodos com ausência de dados comprometeu a capacidade da WRNA em capturar as características das séries.

No entanto, apesar das limitações, observa-se que WRNA consegue capturar a tendência geral das séries, especialmente nos momentos de pico.

Na bacia do Castanhão os meses de abril a agosto apresentaram as melhores correlações e índices de *Nash* nas simulações, enquanto que observou-se um desempenho inferior nos meses de fevereiro, novembro e dezembro.

Os índices estatísticos foram representativos apenas na bacia do Castanhão. Nas bacias do Orós e Banabuiú, as correlações apresentaram valores inconsistentes para todos os períodos analisados, desta forma as tabelas contendo os índices destas bacias estão apresentadas apenas no Anexo C deste trabalho.

Tabela 14 – Previsões (WRNA) - Retiro Baixo

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.987	0.963	0.969	0.963	0.966	0.991	0.863	0.882	0.827	0.92	0.933	0.873
	NASH	0.959	0.92	0.841	0.925	0.861	0.974	0.686	0.748	0.223	0.75	0.864	0.723
	RMSE	9.294	16.556	17.138	9.202	3.377	2.904	4.19	4.354	5.833	8.017	8.327	32.237
14 dias	r	0.966	0.949	0.948	0.958	0.873	0.988	0.799	0.858	0.401	0.767	0.919	0.789
	NASH	0.858	0.883	0.83	0.913	0.303	0.971	0.475	0.713	-5.138	0.229	0.835	0.476
	RMSE	17.293	20.152	17.749	9.915	7.574	3.074	5.422	4.644	16.39	14.094	9.18	44.374
21 dias	r	0.975	0.954	0.87	0.942	0.859	0.989	0.818	0.941	0.725	0.839	0.88	0.814
	NASH	0.548	0.895	0.534	0.884	-0.487	0.929	0.083	0.363	-3.059	0.461	0.683	0.581
	RMSE	30.805	20.172	29.341	11.425	11.06	4.82	7.161	6.919	13.329	11.778	12.732	39.651
28 dias	r	0.976	0.84	0.897	0.945	0.937	0.97	0.824	0.939	0.702	0.914	0.901	0.876
	NASH	0.574	0.128	0.721	0.882	0.345	0.866	-0.162	0.467	-2.086	0.716	0.779	0.697
	RMSE	29.902	24.277	40.833	11.561	7.34	6.641	8.064	6.33	11.622	8.551	10.634	33.761
35 dias	r	0.978	0.695	0.693	0.874	0.698	0.871	0.756	0.764	0.644	0.703	0.834	0.527
	NASH	0.284	-0.632	0.48	0.632	-2.014	0.742	-0.295	0.001	-2.705	0.222	0.684	-0.003
	RMSE	38.779	33.21	57.531	20.387	15.744	9.22	8.51	8.664	12.734	14.154	12.708	61.389
42 dias	r	0.941	0.335	0.47	0.792	0.723	0.623	0.783	0.658	-0.067	0.066	0.55	0.591
	NASH	-1.451	-1.965	0.182	0.286	-7.376	0.064	-3.695	-0.674	-12.604	-3.381	-0.337	0.136
	RMSE	71.746	44.765	75.211	28.388	26.247	17.56	16.207	11.216	24.401	33.594	26.132	56.986

Fonte: Elaborado pelo Autor, 2023

Tabela 15 – Previsões (WRNA) - Três Marias

Previsão	Índices	Jan	Feb	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.989	0.987	0.983	0.995	0.987	0.985	0.984	0.992	0.96	0.958	0.964	0.951
	NASH	0.968	0.971	0.964	0.981	0.972	0.964	0.953	0.979	0.904	0.912	0.926	0.864
	RMSE	159.891	86.437	48.076	24.173	15.362	20.807	14.779	8.217	13.217	24.527	47.137	169.638
14 dias	r	0.989	0.977	0.977	0.983	0.96	0.98	0.975	0.956	0.865	0.882	0.964	0.93
	NASH	0.974	0.944	0.954	0.963	0.902	0.959	0.947	0.891	0.222	0.695	0.919	0.816
	RMSE	142.784	118.985	54.391	34.054	28.517	22.097	15.098	18.724	37.573	45.669	49.334	197.104
21 dias	r	0.993	0.967	0.98	0.986	0.975	0.976	0.978	0.947	0.845	0.939	0.974	0.942
	NASH	0.982	0.923	0.96	0.953	0.938	0.945	0.939	0.873	0.373	0.878	0.943	0.871
	RMSE	118.786	139.741	50.805	38.366	22.689	25.631	15.513	20.235	33.74	28.828	41.454	165.051
28 dias	r	0.996	0.991	0.98	0.994	0.968	0.983	0.95	0.968	0.832	0.923	0.973	0.945
	NASH	0.991	0.972	0.95	0.983	0.92	0.962	0.889	0.893	0.49	0.848	0.936	0.856
	RMSE	86.06	84.068	56.986	23.013	25.677	21.297	22.844	18.16	30.425	32.225	43.848	174.828
35 dias	r	0.981	0.948	0.984	0.968	0.937	0.96	0.88	0.886	0.671	0.832	0.867	0.949
	NASH	0.955	0.883	0.968	0.93	0.824	0.886	0.716	0.656	-0.517	0.589	0.711	0.898
	RMSE	189.796	172.65	45.301	46.906	38.231	36.881	36.597	31.993	52.466	52.965	93.532	147.113
42 dias	r	0.978	0.874	0.915	0.964	0.807	0.882	0.879	0.762	0.543	0.71	0.751	0.951
	NASH	0.941	0.737	0.81	0.901	0.417	0.719	0.591	0.437	-1.882	0.326	0.503	0.877
	RMSE	216.447	258.276	110.817	55.679	69.529	57.993	43.904	39.063	72.32	67.873	122.526	161.094

Fonte: Elaborado pelo Autor, 2023

Tabela 16 – Previsões (WRNA) - Sobradinho

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.992	0.992	0.965	0.979	0.977	0.963	0.984	0.986	0.989	0.987	0.984	0.953
	NASH	0.982	0.981	0.919	0.953	0.924	0.92	0.959	0.95	0.967	0.966	0.968	0.905
	RMSE	187.853	182.592	134.505	102.743	58.124	37.85	15.975	15.143	20.124	45.202	94.919	301.138
14 dias	r	0.991	0.981	0.935	0.963	0.959	0.96	0.974	0.972	0.98	0.979	0.987	0.94
	NASH	0.981	0.959	0.857	0.923	0.859	0.919	0.947	0.924	0.951	0.955	0.972	0.878
	RMSE	195.362	270.204	178.654	131.919	79.329	38.065	18.026	18.626	24.613	52.031	89.143	341.069
21 dias	r	0.988	0.974	0.937	0.97	0.953	0.948	0.957	0.973	0.975	0.967	0.984	0.943
	NASH	0.974	0.94	0.86	0.938	0.817	0.879	0.908	0.927	0.932	0.928	0.969	0.884
	RMSE	226.44	324.58	176.587	118.787	90.47	46.49	22.141	18.266	28.924	65.679	94.056	332.621
28 dias	r	0.991	0.981	0.926	0.973	0.954	0.962	0.942	0.956	0.98	0.966	0.979	0.94
	NASH	0.981	0.961	0.848	0.939	0.881	0.903	0.876	0.832	0.928	0.915	0.957	0.879
	RMSE	192.678	262.422	184.475	117.52	72.858	41.556	23.427	25.461	29.675	71.459	110.556	340.457
35 dias	r	0.969	0.957	0.89	0.93	0.88	0.71	0.641	0.807	0.91	0.919	0.905	0.903
	NASH	0.927	0.901	0.781	0.861	0.353	0.16	0.073	0.487	0.704	0.821	0.801	0.782
	RMSE	377.375	418.037	221.052	177.458	169.99	122.444	64.125	45.044	60.351	103.861	237.28	455.717
42 dias	r	0.945	0.922	0.815	0.836	0.906	0.665	0.43	0.8	0.745	0.881	0.819	0.863
	NASH	0.873	0.837	0.635	0.648	0.274	0.04	-0.563	0.44	0.44	0.751	0.592	0.697
	RMSE	498.104	537.006	285.458	282.412	180.147	130.928	83.274	47.678	82.969	122.683	339.387	538.151

Fonte: Elaborado pelo Autor, 2023

Tabela 17 – Previsões (WRNA) - Luis Gonzaga

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.854	0.944	0.863	0.822	0.925	0.885	0.563	0.743	0.653	0.854	0.634	0.651
	NASH	0.719	0.877	0.725	0.634	0.847	0.525	0.046	0.477	-0.058	-0.543	0.33	-0.222
	RMSE	94.522	48.235	54.121	69.325	34.796	20.277	22.633	19.686	24.086	38.343	35.738	71.374
14 dias	r	0.813	0.905	0.682	0.722	0.817	0.829	0.414	0.328	0.639	0.826	0.377	0.525
	NASH	0.595	0.817	0.437	0.516	0.65	0.429	-0.37	0.016	0.141	0.119	-0.355	-0.49
	RMSE	113.432	58.777	77.441	79.754	52.549	22.233	20.698	27.001	21.699	28.97	50.835	78.814
21 dias	r	0.878	0.917	0.759	0.789	0.854	0.905	0.283	0.701	0.706	0.819	0.657	0.593
	NASH	0.695	0.834	0.568	0.587	0.712	0.425	-1.254	0.468	-0.041	-0.22	0.344	-0.169
	RMSE	98.429	55.887	67.858	73.656	47.691	22.312	26.882	19.855	23.887	34.102	35.366	69.833
28 dias	r	0.903	0.944	0.875	0.824	0.924	0.937	0.744	0.733	0.563	0.86	0.634	0.712
	NASH	0.815	0.886	0.754	0.629	0.844	0.626	0.5	0.522	-0.075	-0.467	0.365	-0.027
	RMSE	76.659	46.336	51.222	69.827	35.086	18.0	31.479	19.244	24.278	37.39	34.806	65.431
35 dias	r	0.724	0.808	0.712	0.376	0.793	0.759	0.582	0.299	0.511	0.754	0.43	0.523
	NASH	0.504	0.644	0.473	0.082	0.544	-0.45	0.308	-0.185	-0.426	-0.242	-0.43	-0.074
	RMSE	125.485	81.983	74.938	109.804	60.012	35.433	37.024	30.359	27.962	34.409	52.229	66.934
42 dias	r	0.776	0.465	0.669	0.019	0.527	0.627	0.094	-0.211	0.532	0.695	0.209	0.391
	NASH	0.536	0.184	0.352	-0.115	0.209	-0.787	-0.128	-0.706	-0.348	0.127	-0.17	-0.039
	RMSE	121.392	124.099	83.103	121.008	79.027	39.345	47.269	37.215	27.187	28.836	47.237	65.83

Fonte: Elaborado pelo Autor, 2023

Tabela 18 – Previsões (WRNA) - Paulo Afonso

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.885	0.93	0.895	0.941	-0.025	0.25	0.686	0.796	-0.172	0.248	0.073	0.655
	NASH	0.727	0.853	0.754	0.85	-1.04	-0.719	-0.279	0.568	-6.53	0.054	-90.091	0.389
	RMSE	38.766	24.803	63.657	48.047	71.529	31.212	9.74	25.572	33.654	62.654	56.806	63.55
14 dias	r	0.848	0.91	0.823	0.894	-0.145	-0.087	0.775	0.564	0.251	0.001	0.35	0.561
	NASH	0.626	0.814	0.666	0.796	-3.111	-10.543	0.287	0.045	-0.567	-0.313	-6.708	-0.205
	RMSE	45.357	27.912	74.186	55.956	101.532	80.879	7.273	38.009	15.351	73.825	16.524	90.638
21 dias	r	0.846	0.938	0.836	0.956	0.031	0.233	0.765	0.84	0.027	0.696	0.101	0.737
	NASH	0.631	0.852	0.685	0.861	-1.153	-0.903	0.17	0.626	-3.844	0.379	-68.678	0.526
	RMSE	45.013	24.903	72.045	46.229	73.487	32.842	7.844	23.8	26.994	50.76	49.683	57.78
28 dias	r	0.848	0.904	0.883	0.949	0.007	-0.024	0.642	0.747	-0.246	0.647	0.211	0.708
	NASH	0.66	0.812	0.768	0.89	-1.943	-4.076	-1.324	0.546	-6.019	0.379	-28.656	0.348
	RMSE	43.194	28.047	61.823	41.045	85.908	53.636	13.128	26.214	32.494	50.779	32.413	69.17
35 dias	r	0.673	0.498	0.715	0.682	0.299	0.622	-0.061	0.724	0.755	0.414	-0.063	0.175
	NASH	0.435	0.247	0.317	0.365	0.084	0.331	-3.134	0.312	-4.706	0.133	-58.923	0.007
	RMSE	55.698	56.183	106.021	98.724	47.929	19.476	17.508	32.262	29.297	59.981	46.074	87.259
42 dias	r	0.571	0.338	0.592	0.63	0.3	0.667	-0.113	0.576	0.789	0.545	-0.191	0.208
	NASH	0.281	0.107	0.204	0.297	0.064	0.159	-5.95	0.23	-3.169	0.237	-65.202	-0.015
	RMSE	74.439	61.173	114.487	103.877	48.449	21.829	22.701	34.141	25.043	56.258	48.427	66.797

Fonte: Elaborado pelo Autor, 2023

Tabela 19 – Previsões (WRNA) - Xingó

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.891	0.933	0.807	0.975	0.444	0.42	0.87	0.904	0.927	0.518	0.646	0.955
	NASH	0.786	0.869	0.456	0.922	-0.519	-0.362	0.163	0.438	0.855	0.257	-0.184	0.727
	RMSE	80.714	55.969	76.954	54.996	61.45	25.561	6.033	31.478	29.21	61.947	54.051	83.987
14 dias	r	0.902	0.915	0.798	0.98	0.249	0.193	0.942	0.867	0.99	0.329	0.629	0.944
	NASH	0.786	0.83	0.174	0.951	-2.542	-9.656	0.797	0.103	0.976	0.033	-0.06	0.848
	RMSE	80.769	63.946	94.866	43.389	93.841	71.499	2.97	39.759	11.946	70.695	51.138	63.62
21 dias	r	0.854	0.895	0.752	0.963	0.483	0.514	0.702	0.932	0.963	0.713	0.534	0.961
	NASH	0.724	0.791	0.34	0.909	-0.394	-0.347	0.085	0.652	0.926	0.466	-0.745	0.847
	RMSE	91.602	70.764	84.788	59.299	58.872	25.418	6.311	24.762	20.899	52.538	65.622	64.779
28 dias	r	0.876	0.904	0.838	0.979	0.337	0.332	0.826	0.882	0.97	0.654	0.612	0.968
	NASH	0.731	0.809	0.486	0.953	-2.058	-4.498	0.31	0.214	0.939	0.388	-0.253	0.906
	RMSE	90.527	67.681	74.793	42.475	87.198	51.356	5.479	37.209	19.009	56.23	55.614	51.636
35 dias	r	0.732	0.541	0.573	0.791	0.722	0.773	0.66	0.882	0.905	0.739	0.347	0.696
	NASH	0.503	0.282	0.295	0.617	0.387	-0.167	-3.966	0.718	0.782	0.437	-0.905	0.376
	RMSE	123.08	131.238	87.624	121.832	39.033	23.659	14.698	22.301	35.841	53.913	68.559	135.755
42 dias	r	0.566	0.304	0.335	0.708	0.595	0.783	0.556	0.84	0.936	0.702	0.324	0.507
	NASH	0.263	-0.014	0.085	0.49	-0.092	-0.783	-11.234	0.63	0.787	0.424	-0.872	0.212
	RMSE	105.449	155.991	99.824	140.68	52.104	29.25	23.071	25.547	35.373	54.551	67.971	75.018

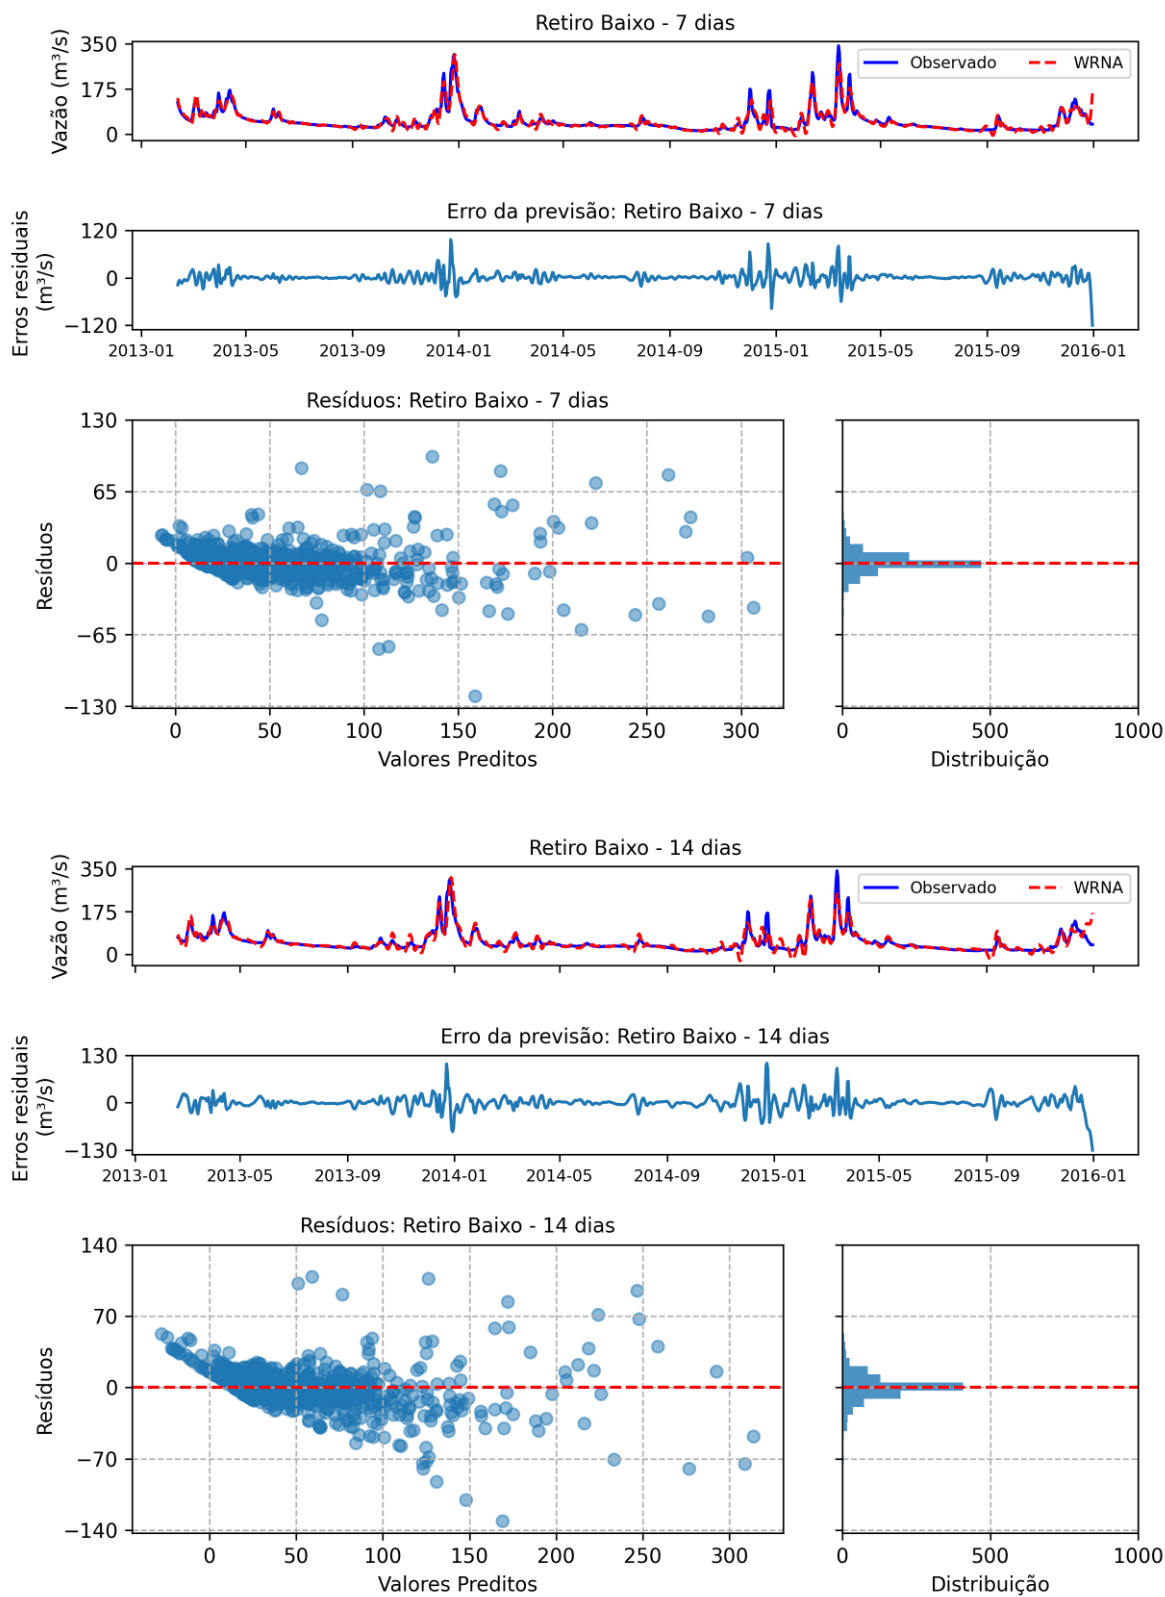
Fonte: Elaborado pelo Autor, 2023

Tabela 20 – Previsões (WRNA) - Castanhão

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	0.266	0.046	0.616	0.929	0.981	0.996	0.959	0.865	0.901	0.706	0.702	0.485
	NASH	-2.473	-5.335	-0.194	0.836	0.963	0.989	0.879	0.701	0.647	0.354	-0.158	-6.602
	RMSE	16.844	12.633	18.776	69.961	73.506	6.226	6.109	3.221	1.994	10.698	4.925	14.072
14 dias	r	0.366	0.104	0.648	0.872	0.973	0.994	0.956	0.91	0.828	0.658	0.289	0.137
	NASH	-1.712	-4.442	0.051	0.756	0.94	0.95	0.896	0.8	0.054	-0.128	-1.465	-9.271
	RMSE	14.884	11.709	16.741	85.434	93.338	13.472	5.652	2.636	3.267	14.646	7.186	16.357
21 dias	r	0.435	0.131	0.686	0.867	0.967	0.985	0.974	0.812	0.858	0.679	0.139	-0.804
	NASH	-1.773	-9.555	-1.136	0.75	0.924	0.911	0.917	0.075	0.018	0.288	-6.373	-16.15
	RMSE	15.05	16.307	25.116	86.51	104.96	17.956	5.056	5.666	3.328	12.067	12.427	21.136
28 dias	r	0.4	0.042	0.702	0.863	0.954	0.954	0.867	0.814	0.786	0.648	0.47	-0.627
	NASH	-2.178	-16.204	-1.938	0.658	0.909	0.852	0.717	-0.374	-0.865	0.387	-7.161	-28.305
	RMSE	16.113	20.819	29.457	101.048	115.245	23.199	9.346	6.908	4.587	11.621	13.074	27.629
35 dias	r	0.212	0.118	0.651	0.836	0.938	0.931	0.805	0.519	0.355	0.7	0.027	-0.669
	NASH	-1.91	-24.345	-2.479	0.574	0.879	0.852	0.642	-1.637	-4.229	0.365	-8.045	-65.776
	RMSE	15.417	25.269	32.053	112.82	132.661	23.181	10.507	9.569	7.68	11.894	13.905	41.707
42 dias	r	0.441	-0.107	0.575	0.913	0.913	0.873	0.651	0.509	0.445	0.645	-0.174	-0.596
	NASH	-10.05	-196.801	-25.96	0.773	0.823	0.757	0.164	-1.473	-14.56	0.223	-31.6	-319.485
	RMSE	16.212	44.118	53.446	85.018	161.458	33.612	17.6	11.531	15.161	17.748	20.349	71.571

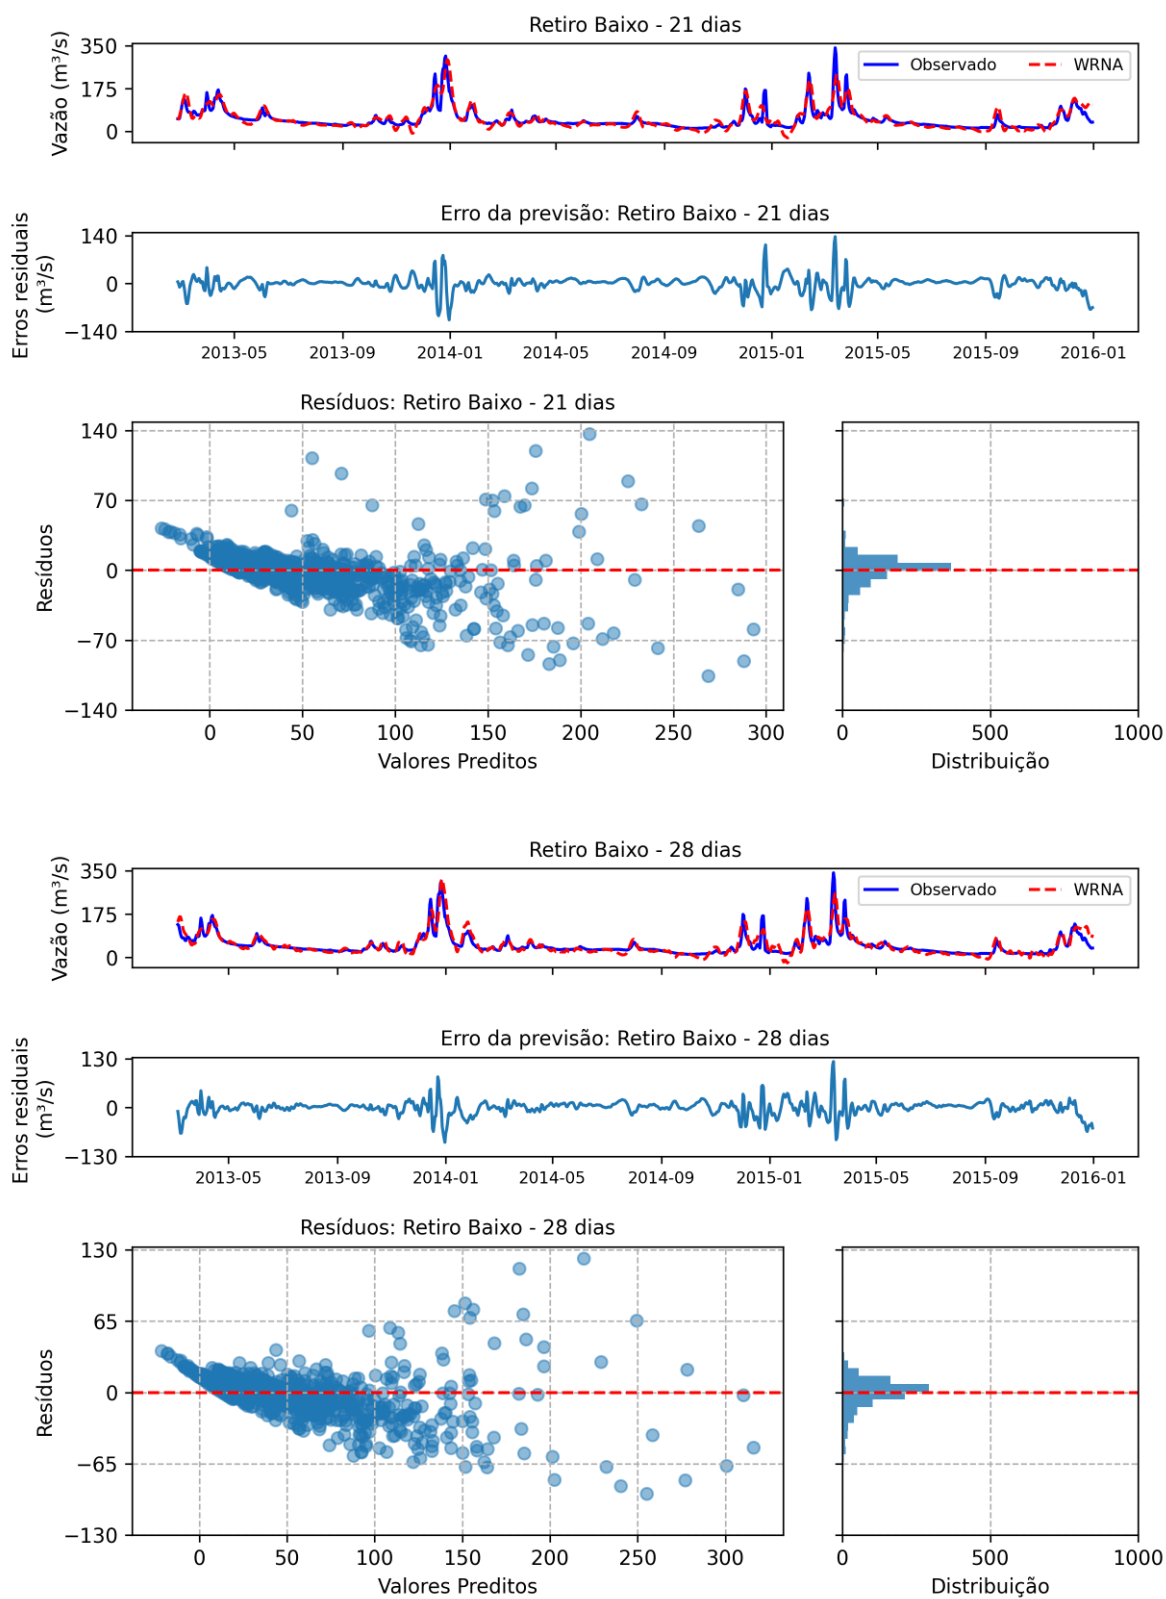
Fonte: Elaborado pelo Autor, 2023

Figura 49 – Previsão WRNA - Retiro Baixo 7 e 14 dias



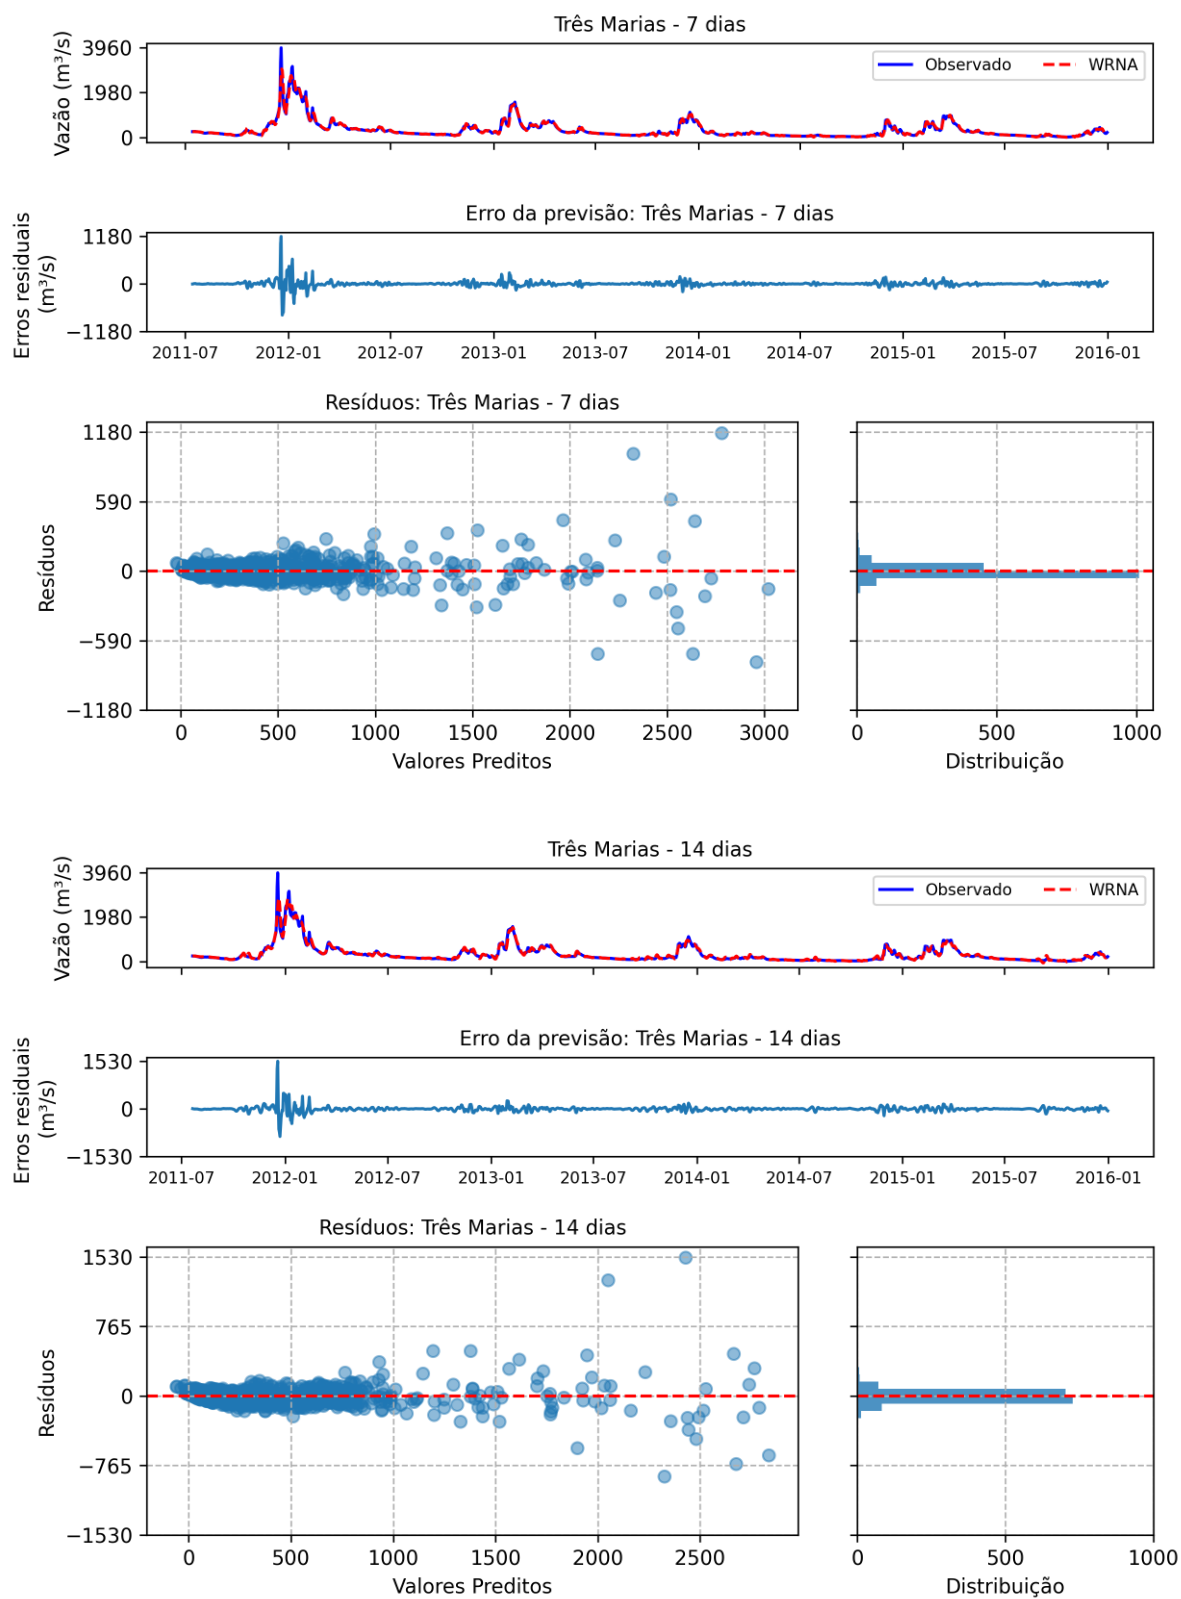
Fonte: Próprio autor

Figura 50 – Previsão WRNA - Retiro Baixo 21 e 28 dias



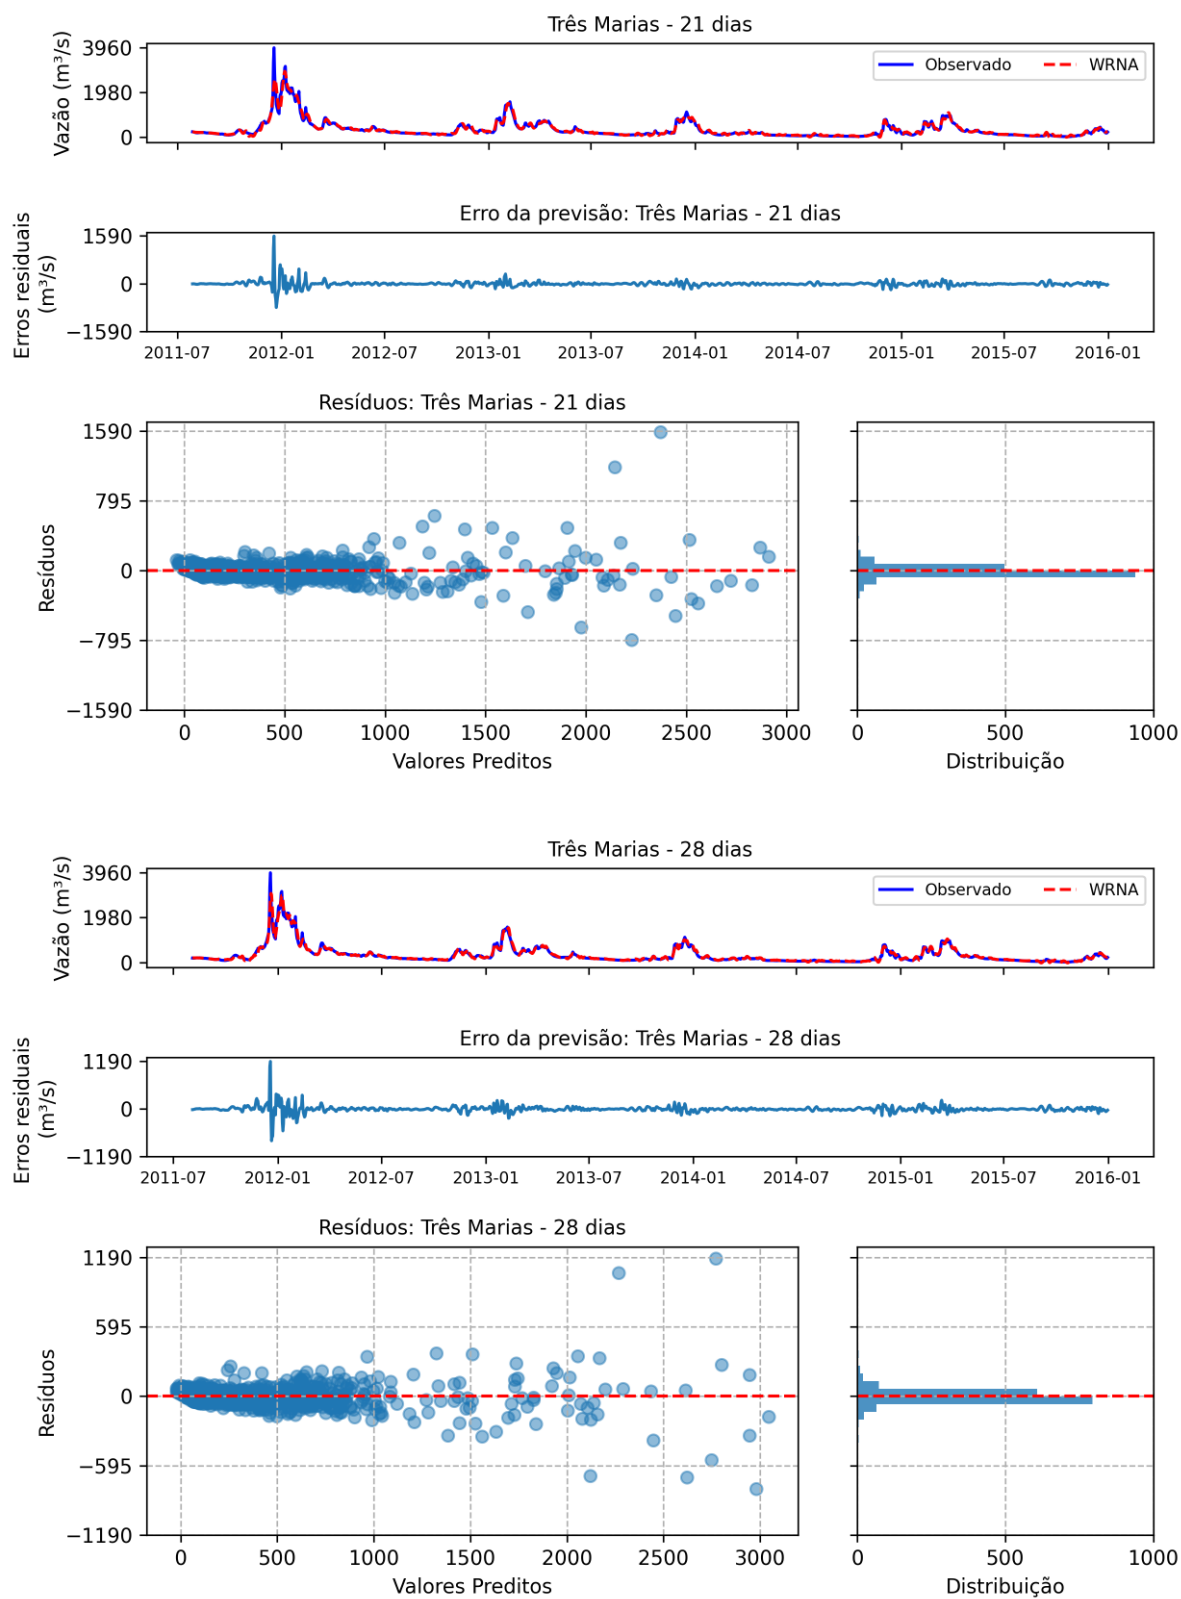
Fonte: Próprio autor

Figura 51 – Previsão WRNA - Três Marias 7 e 14 dias



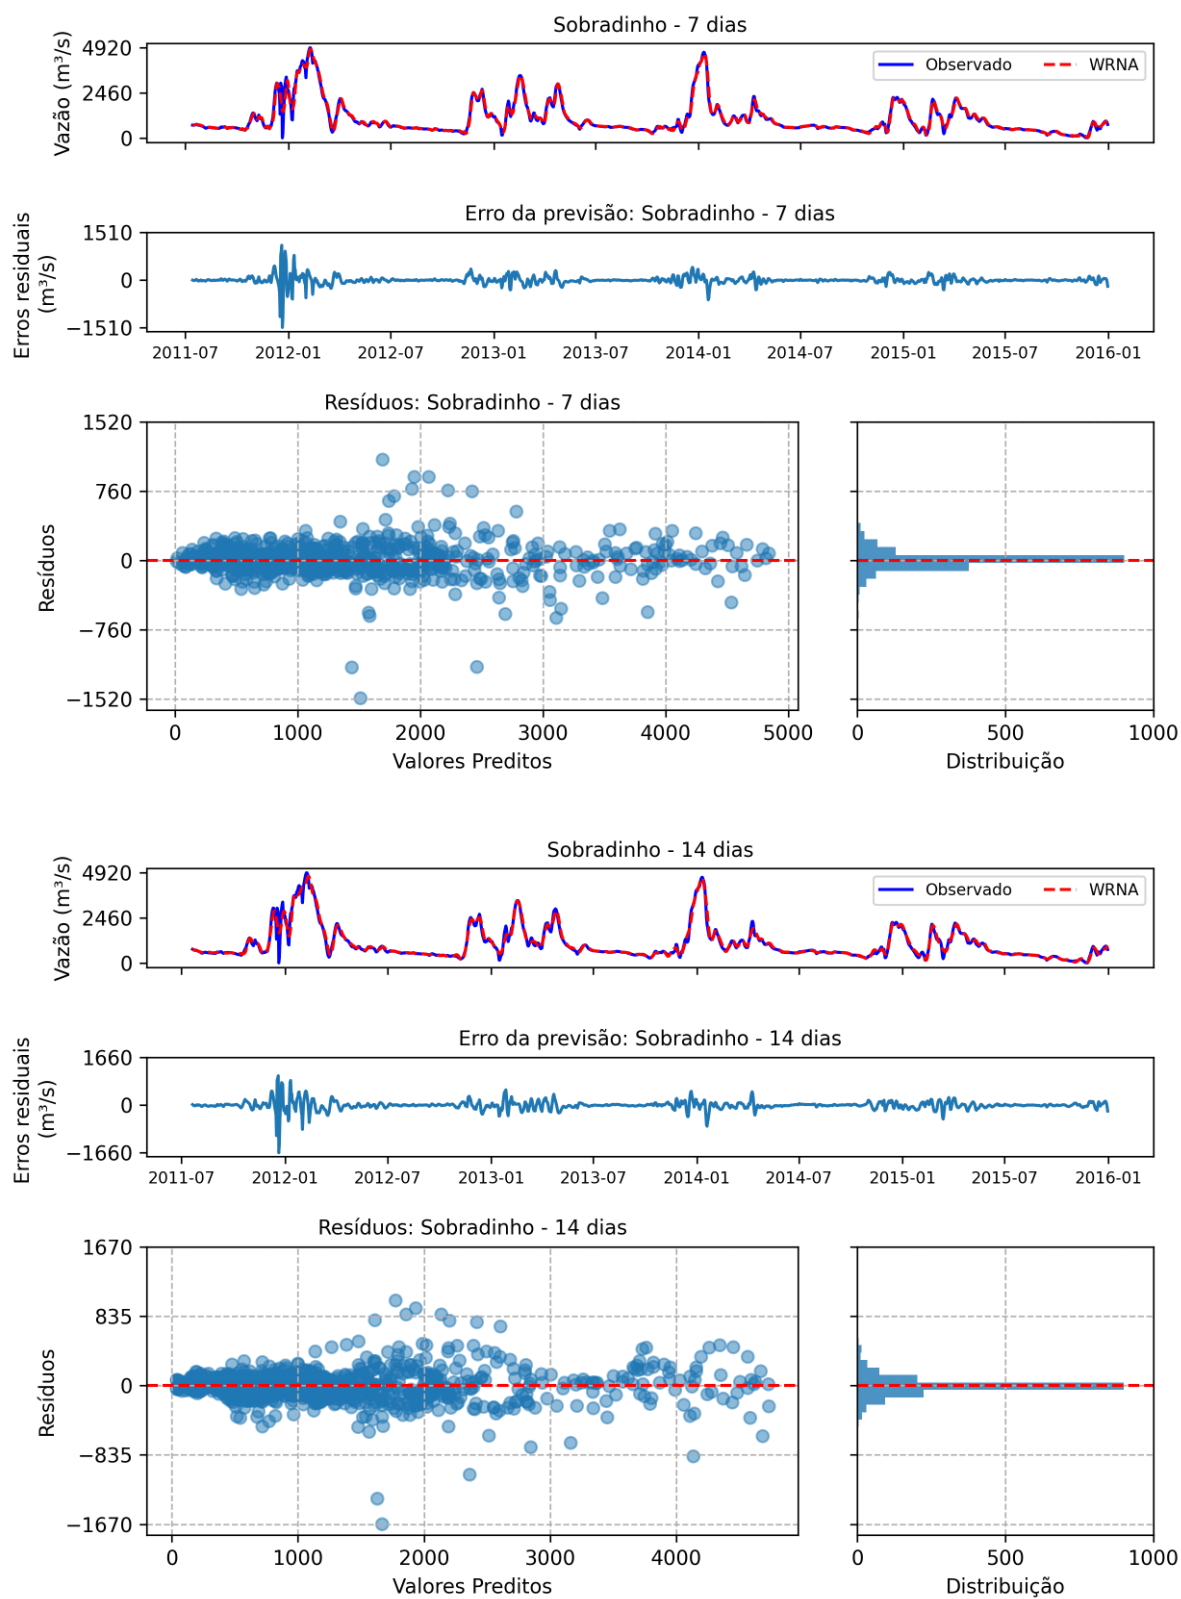
Fonte: Próprio autor

Figura 52 – Previsão WRNA - Três Marias 21 e 28 dias



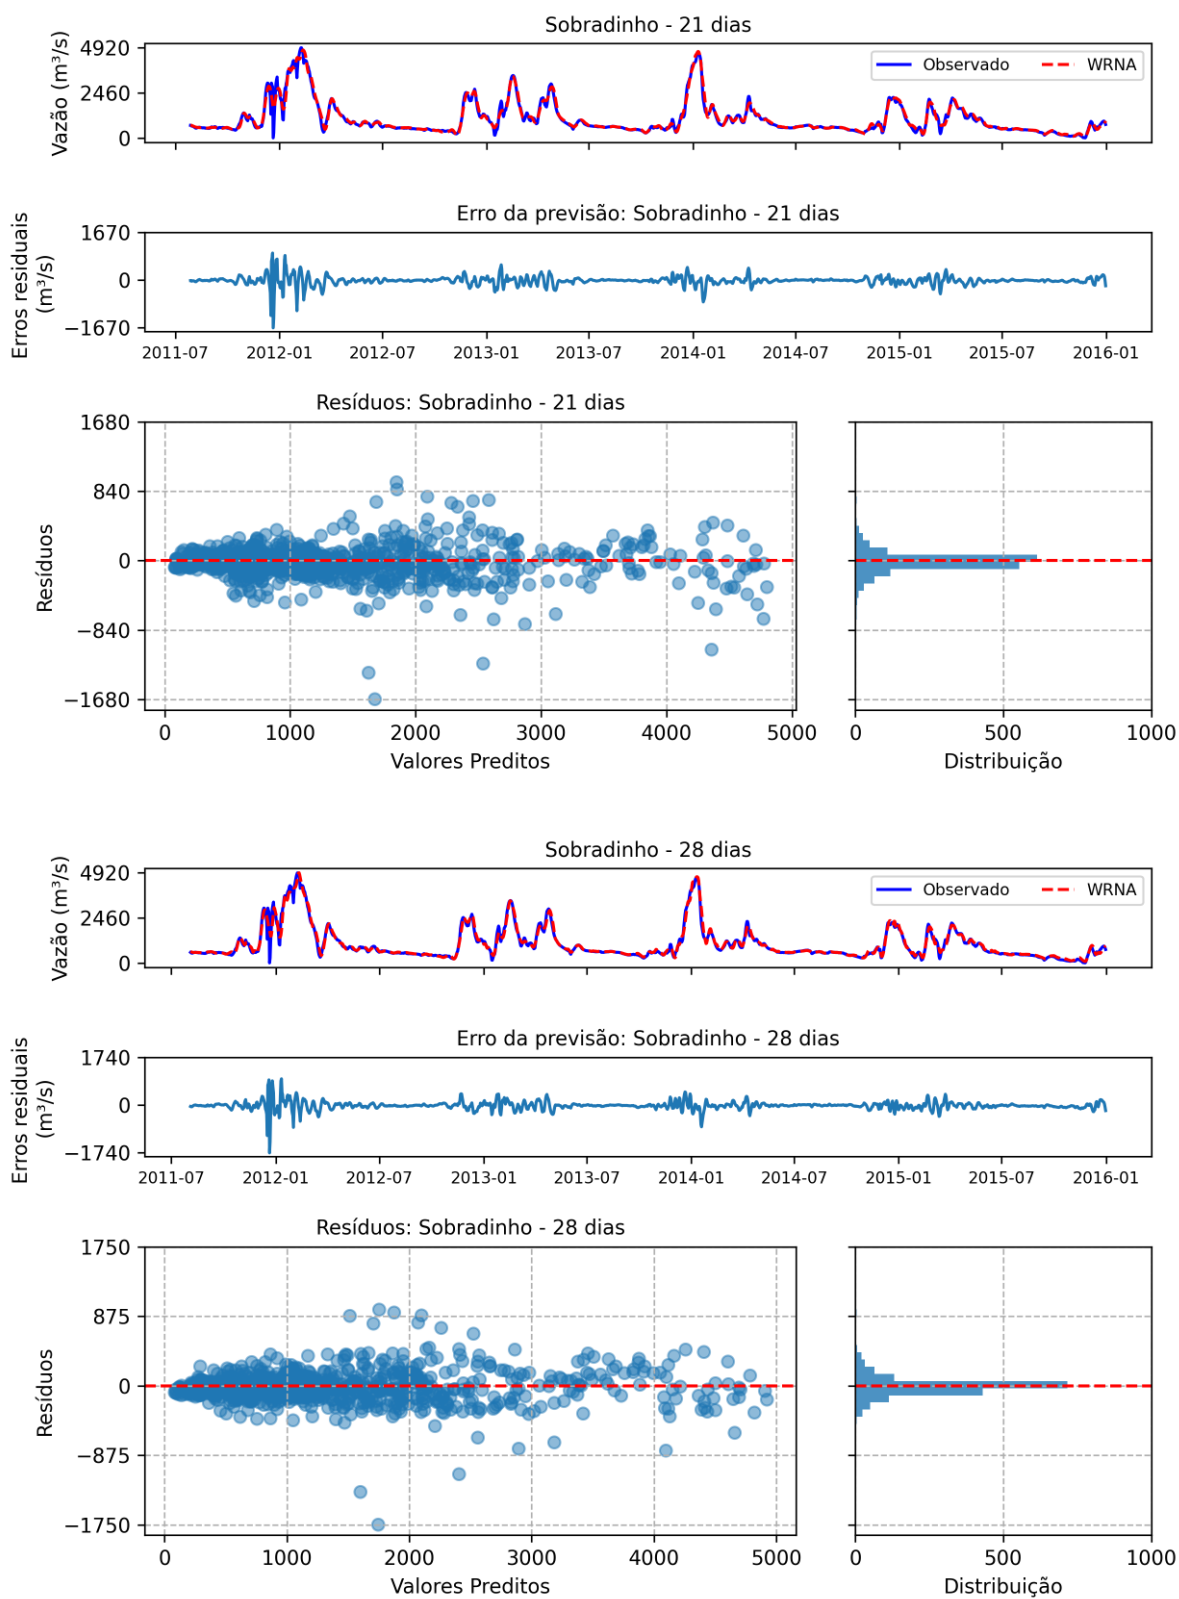
Fonte: Próprio autor

Figura 53 – Previsão WRNA - Sobradinho 7 e 14 dias



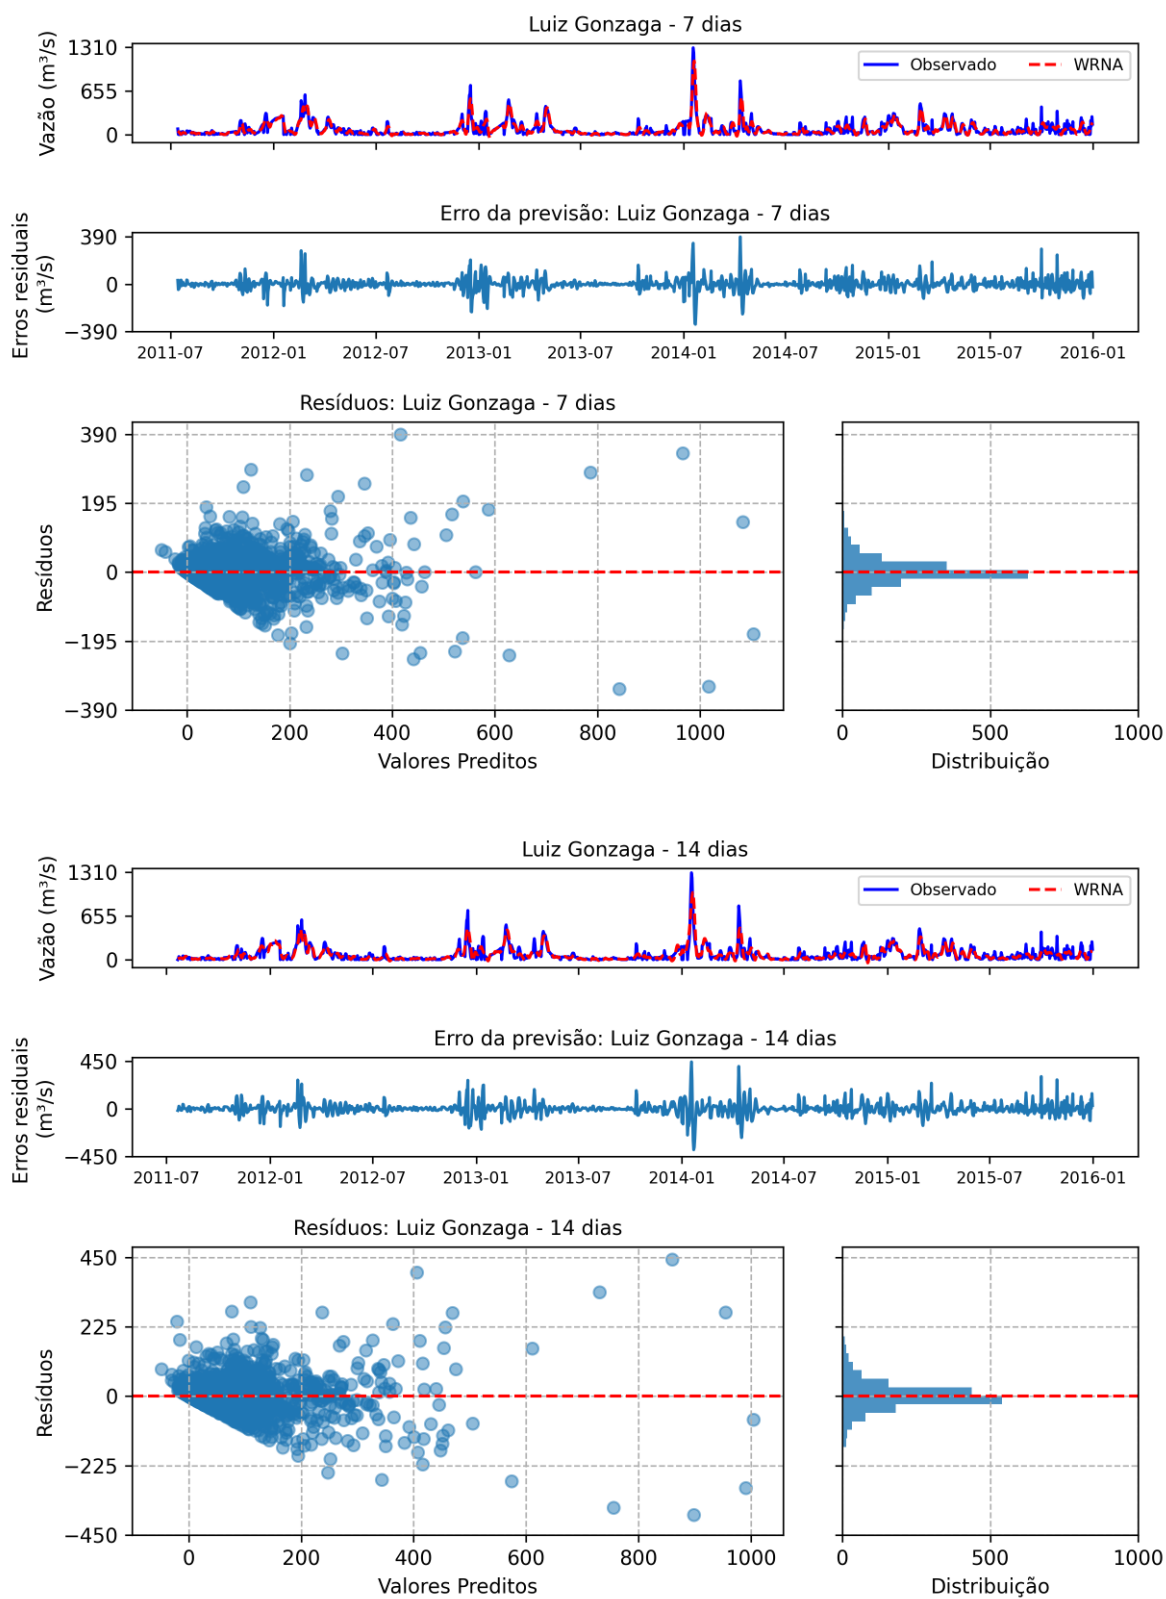
Fonte: Próprio autor

Figura 54 – Previsão WRNA - Sobradinho 21 e 28 dias



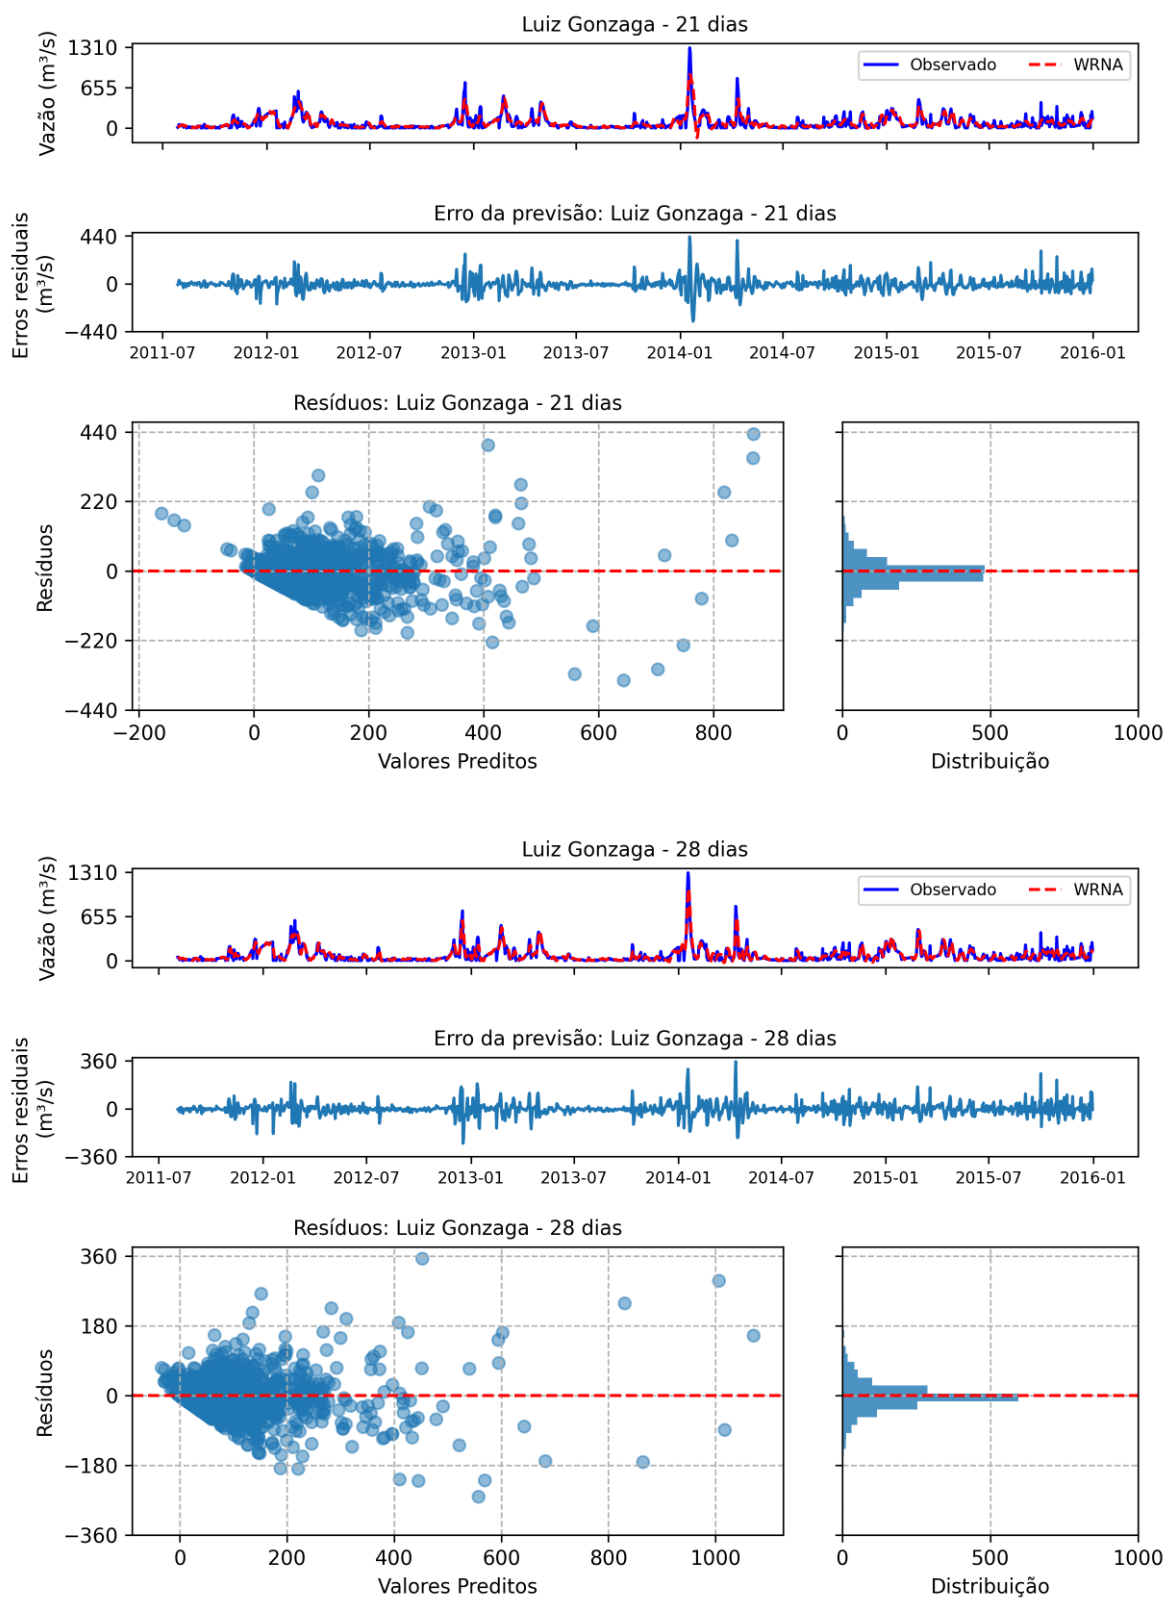
Fonte: Próprio autor

Figura 55 – Previsão WRNA - Luiz Gonzaga 7 e 14 dias



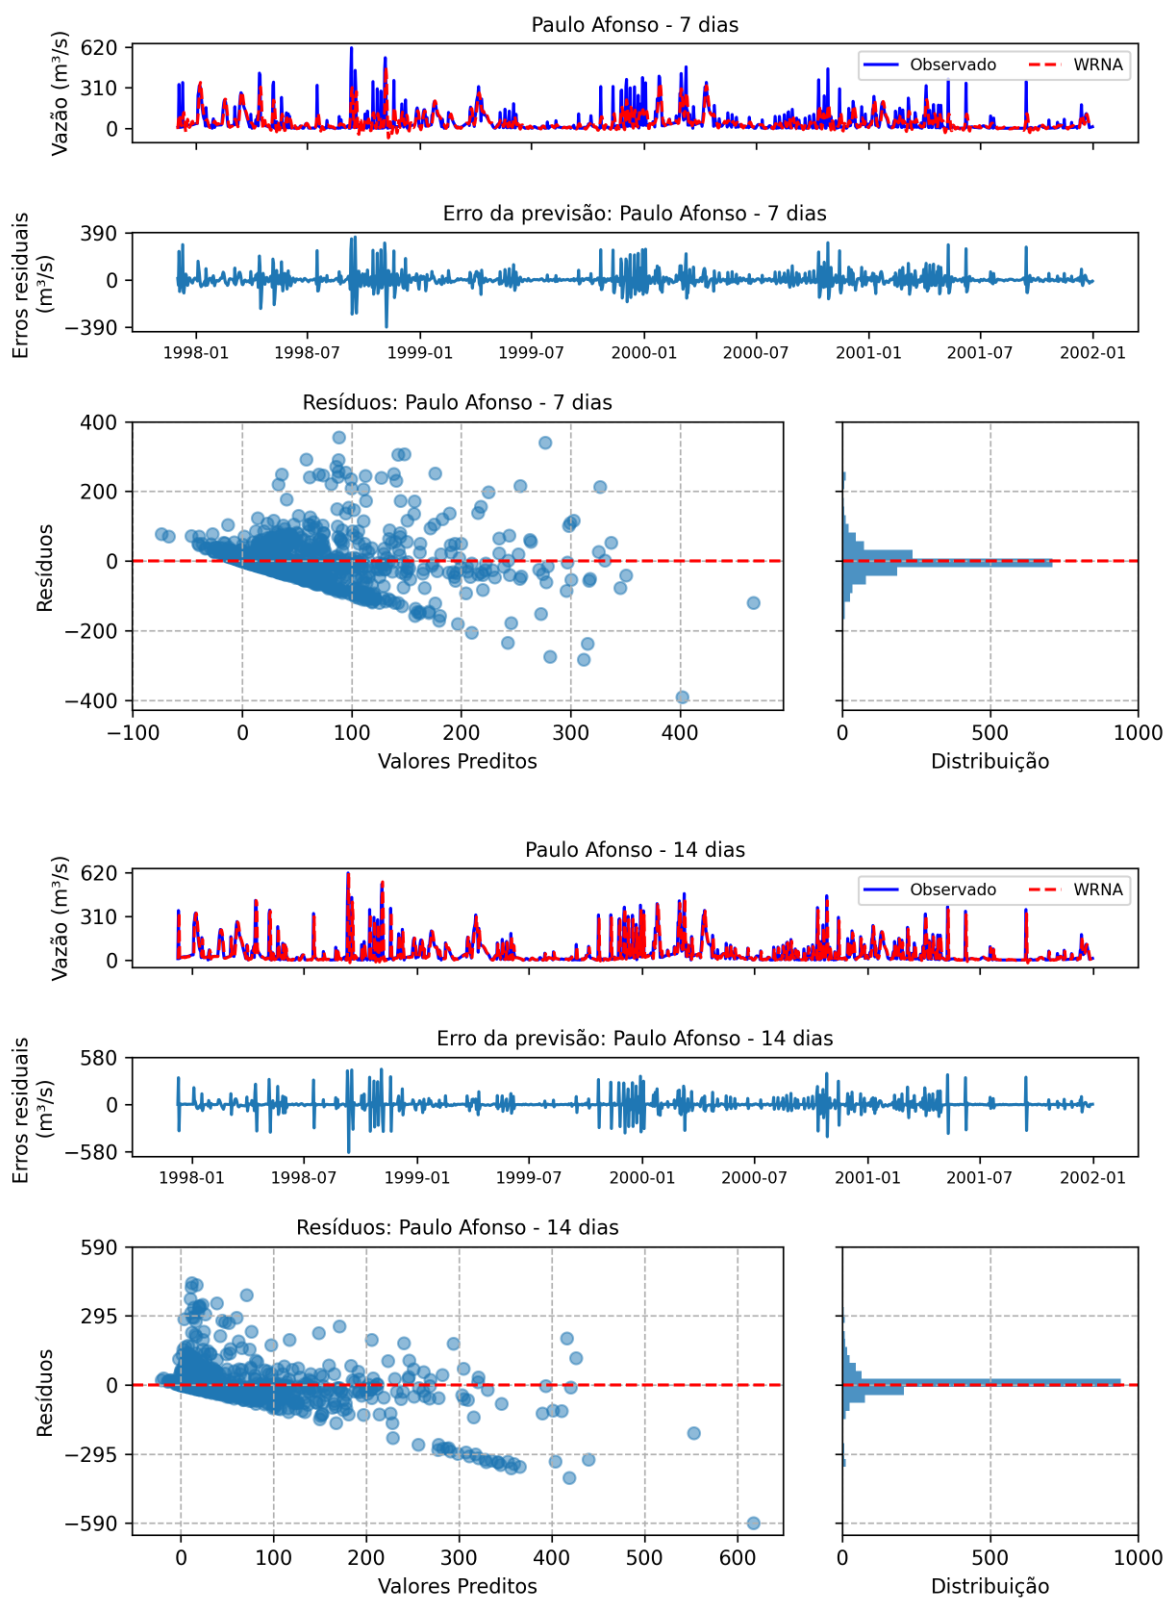
Fonte: Próprio autor

Figura 56 – Previsão WRNA - Luiz Gonzaga 21 e 28 dias



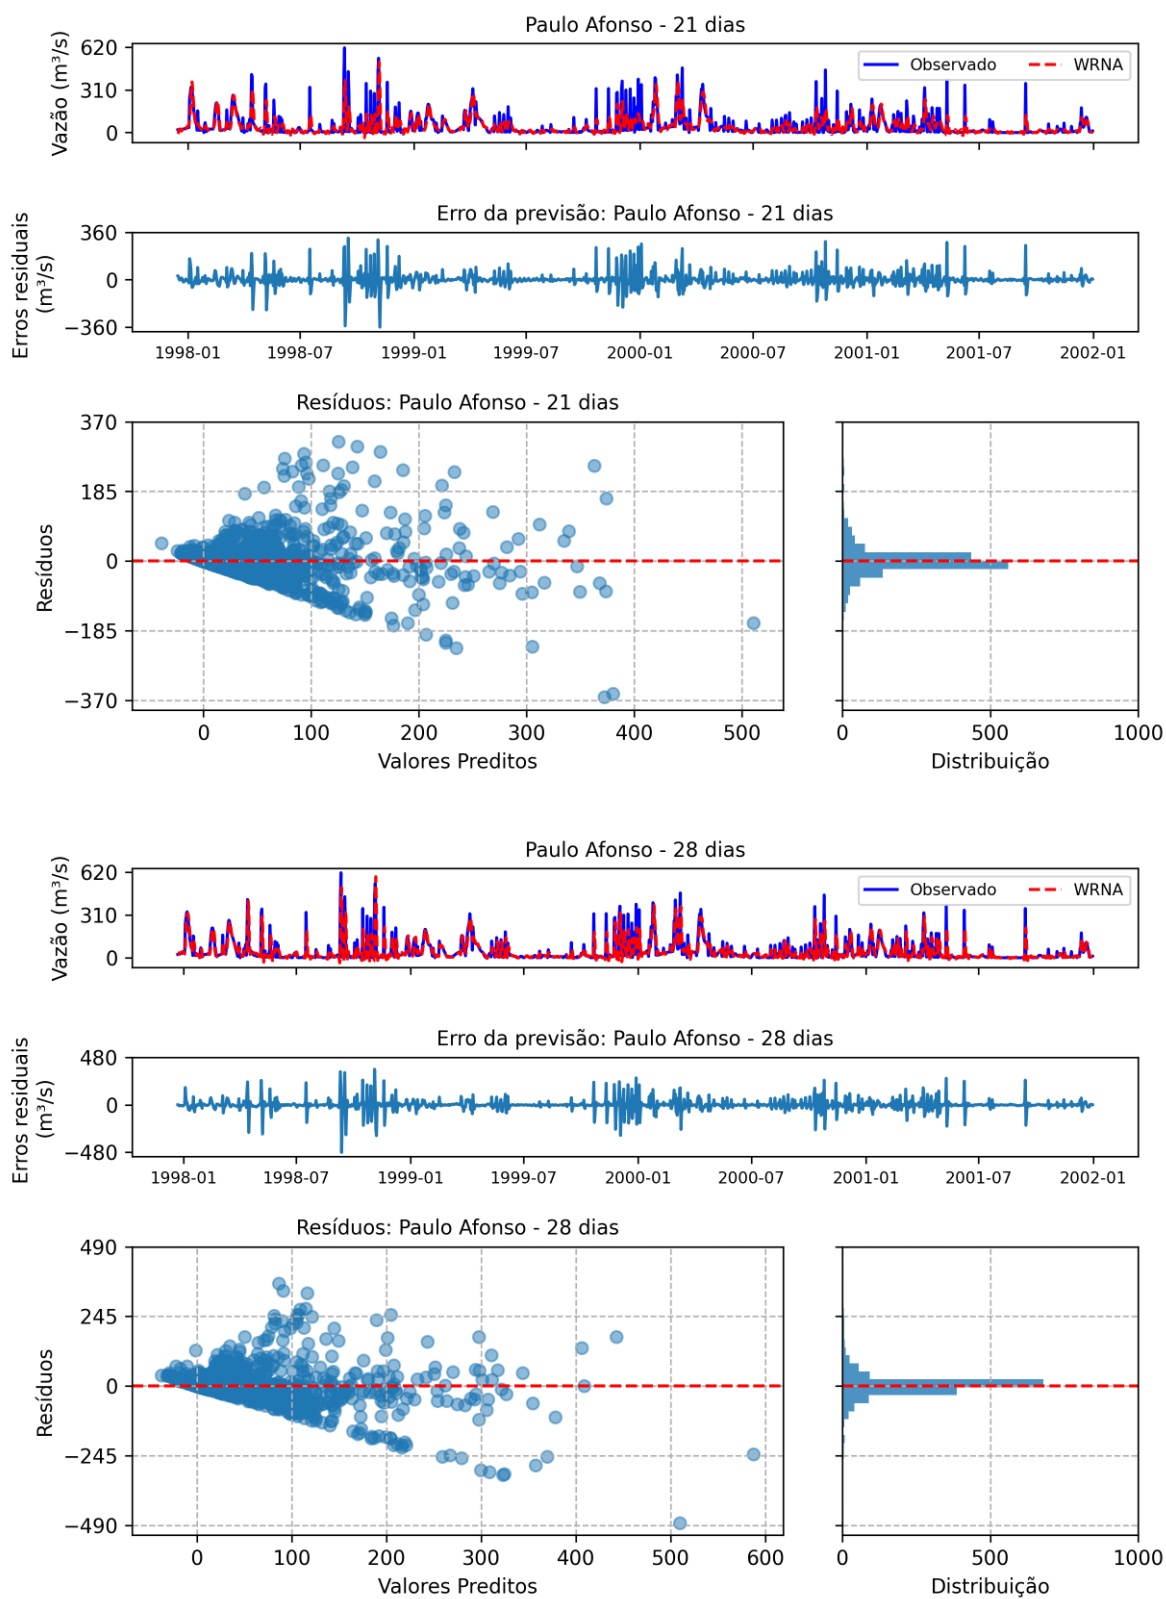
Fonte: Próprio autor

Figura 57 – Previsão WRNA - Paulo Afonso 7 e 14 dias



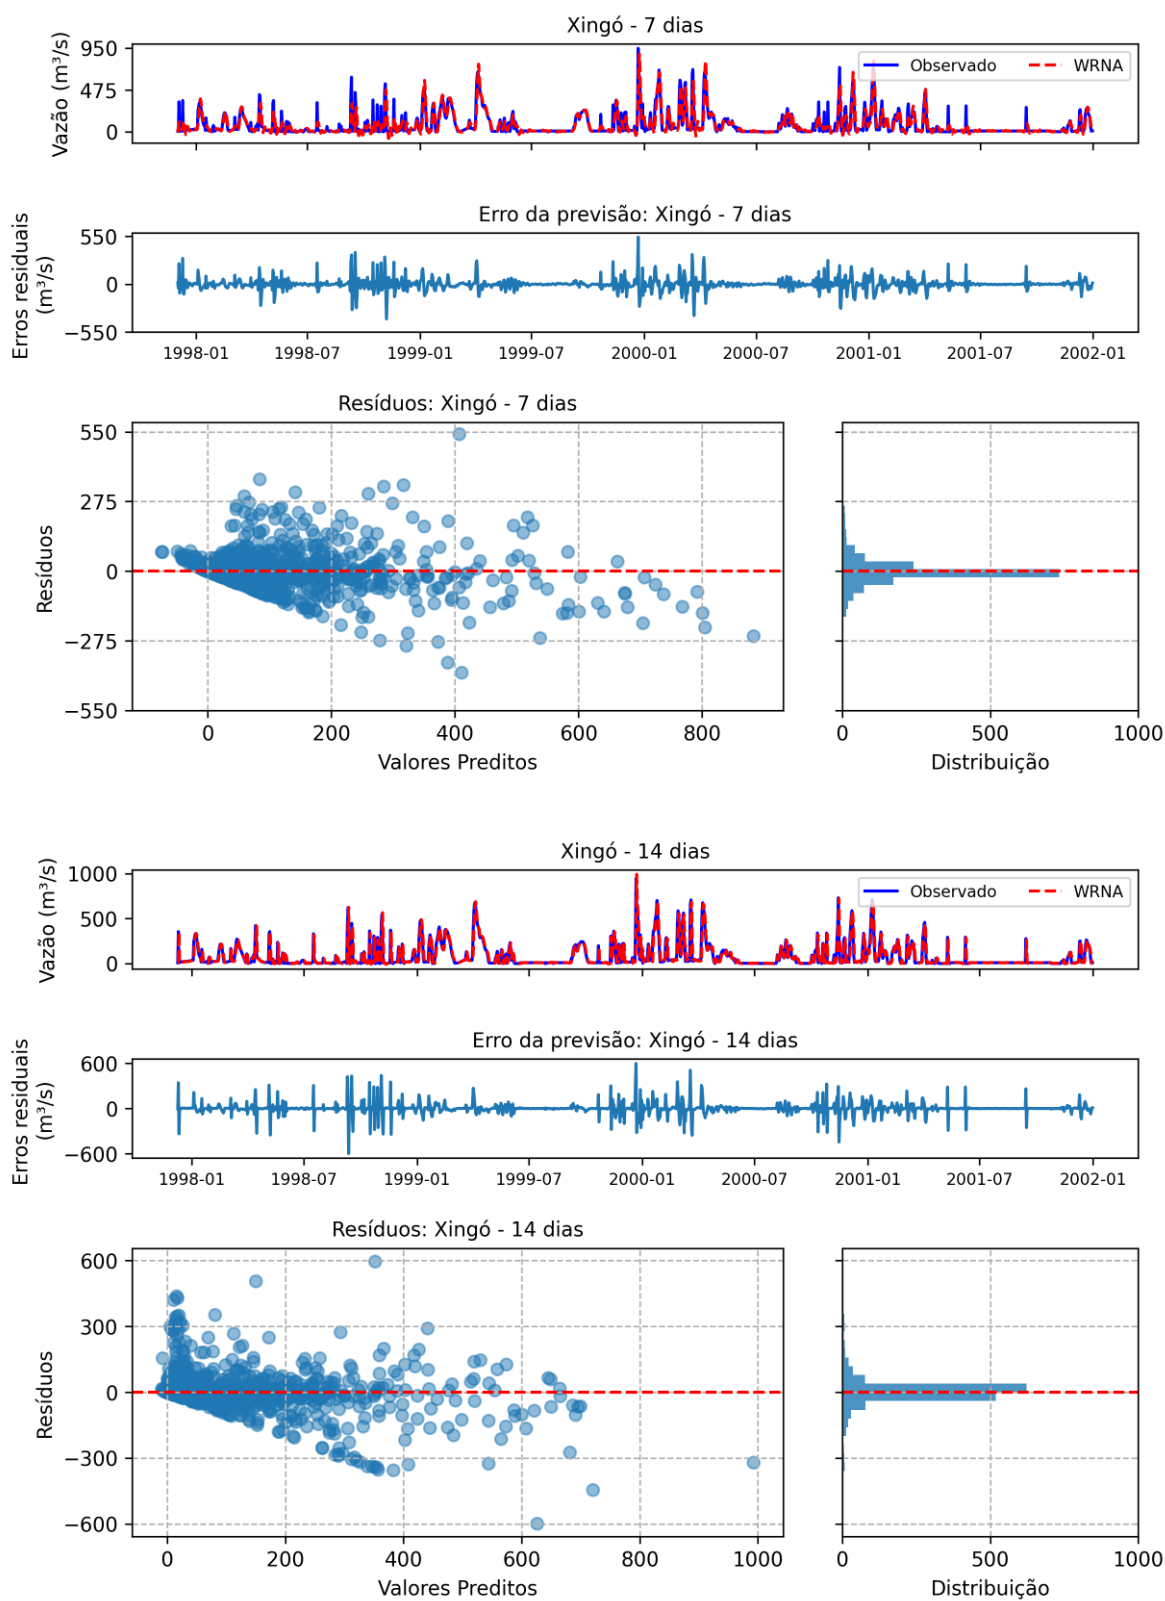
Fonte: Próprio autor

Figura 58 – Previsão WRNA - Paulo Afonso 21 e 28 dias



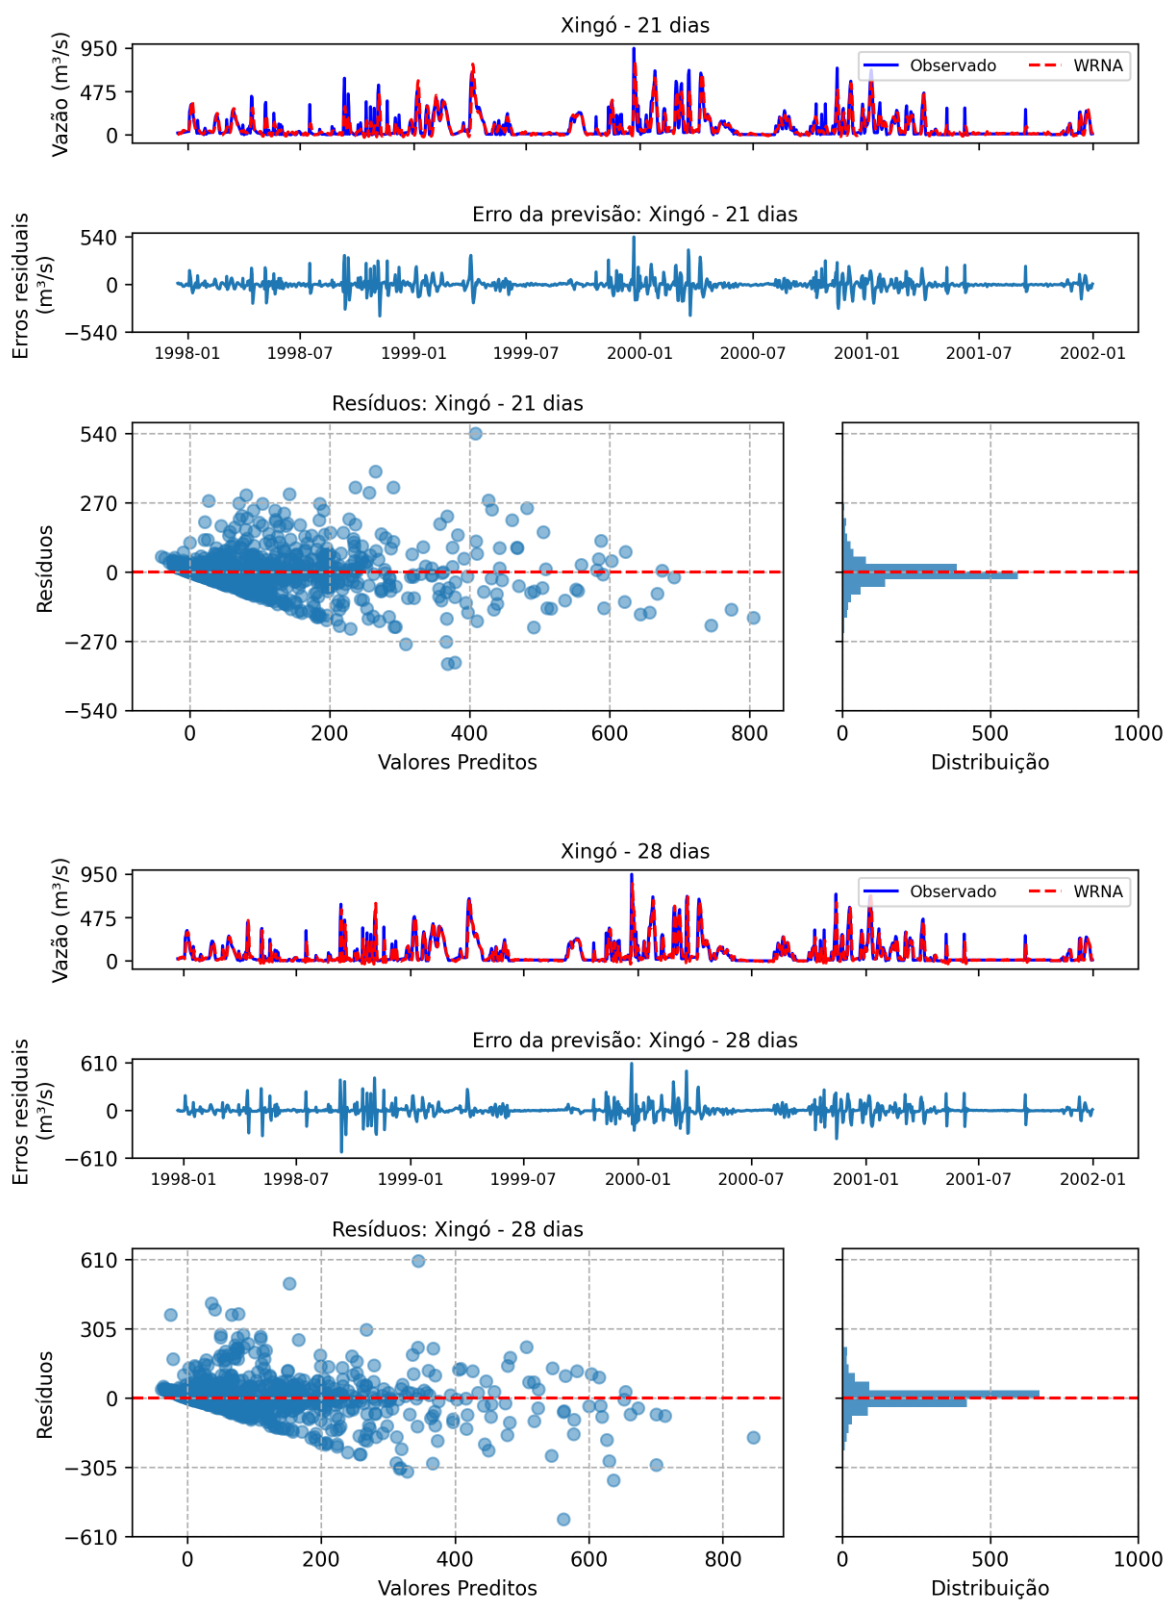
Fonte: Próprio autor

Figura 59 – Previsão WRNA - Xingó 7 e 14 dias



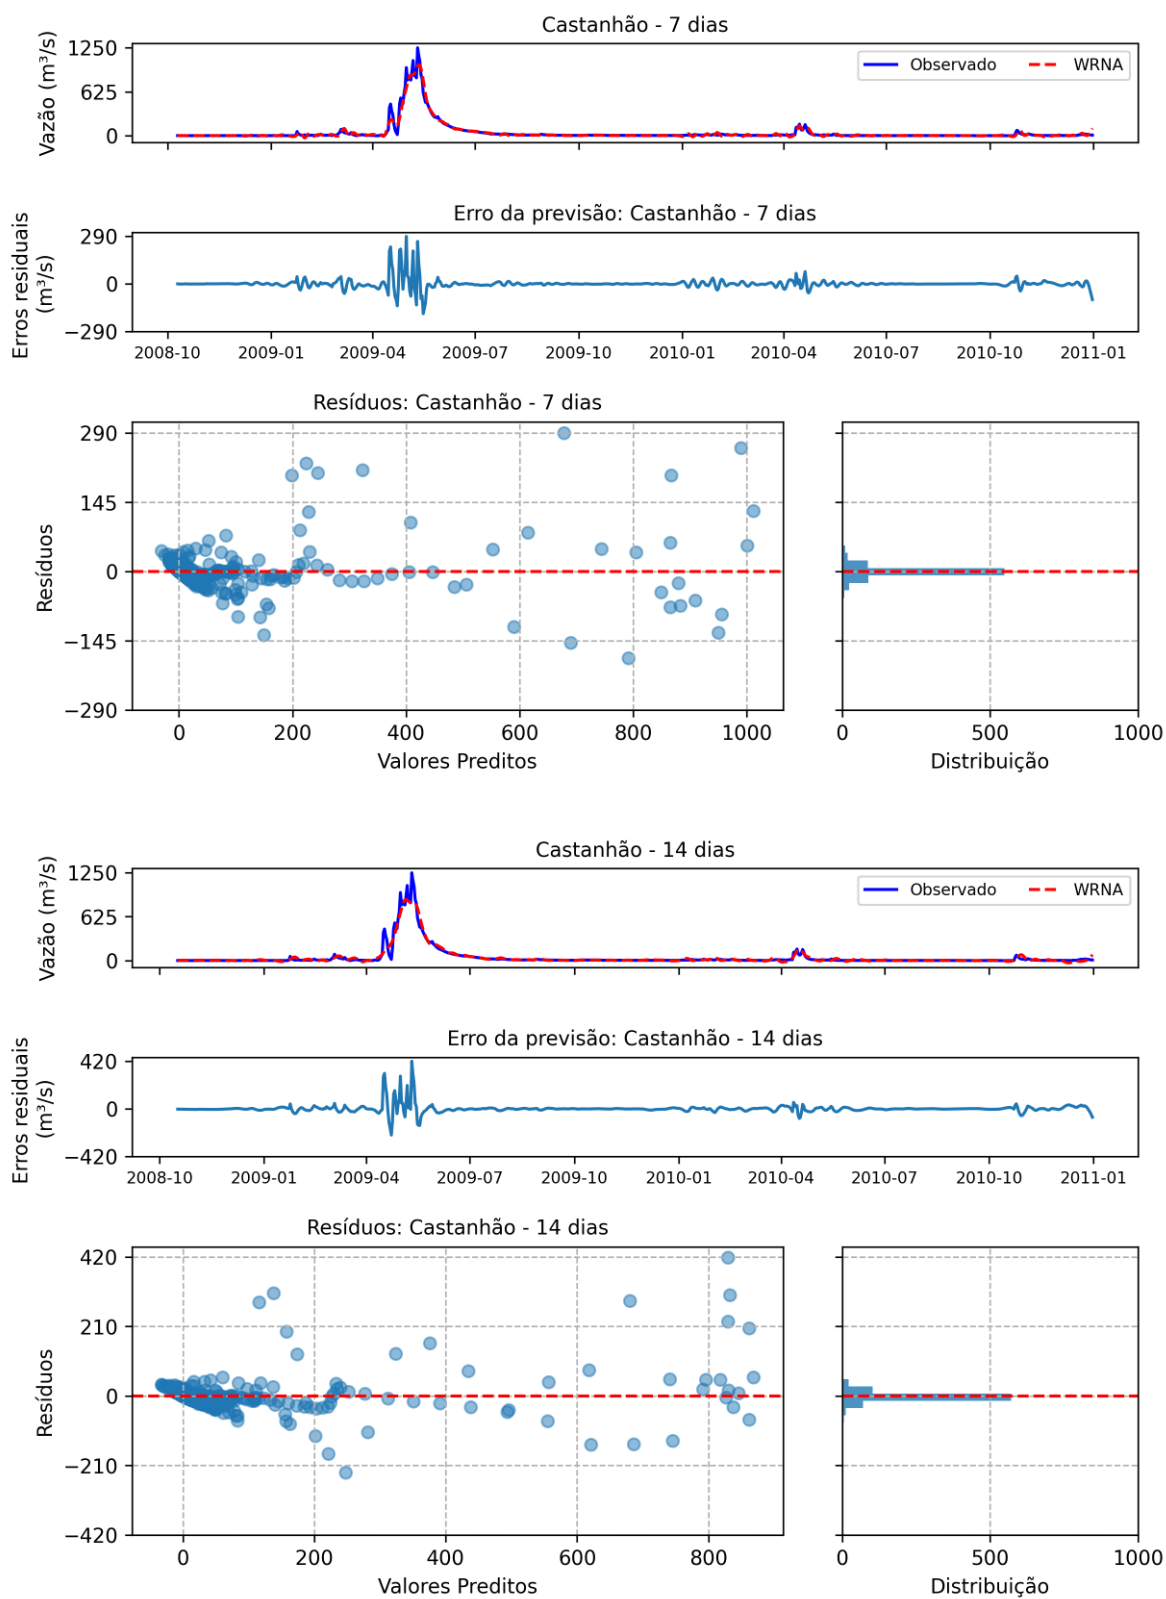
Fonte: Próprio autor

Figura 60 – Previsão WRNA - Xingó 21 e 28 dias



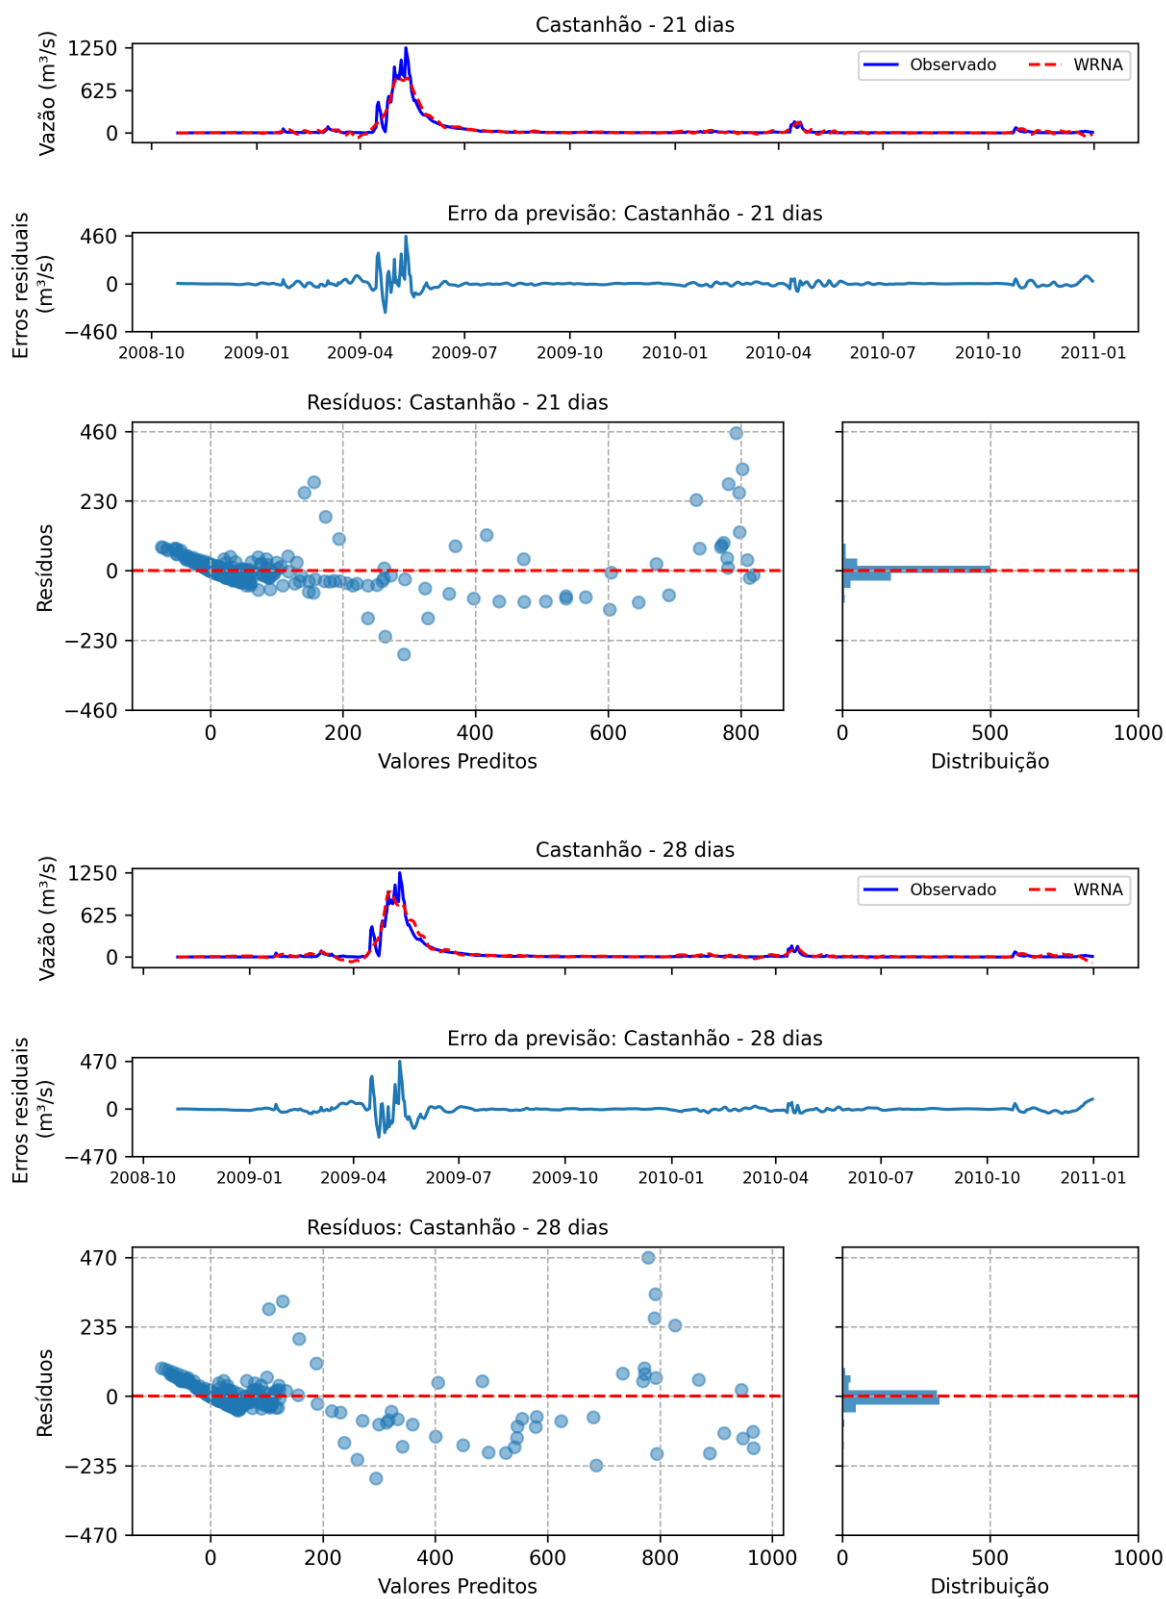
Fonte: Próprio autor

Figura 61 – Previsão WRNA - Castanhão 7 e 14 dias



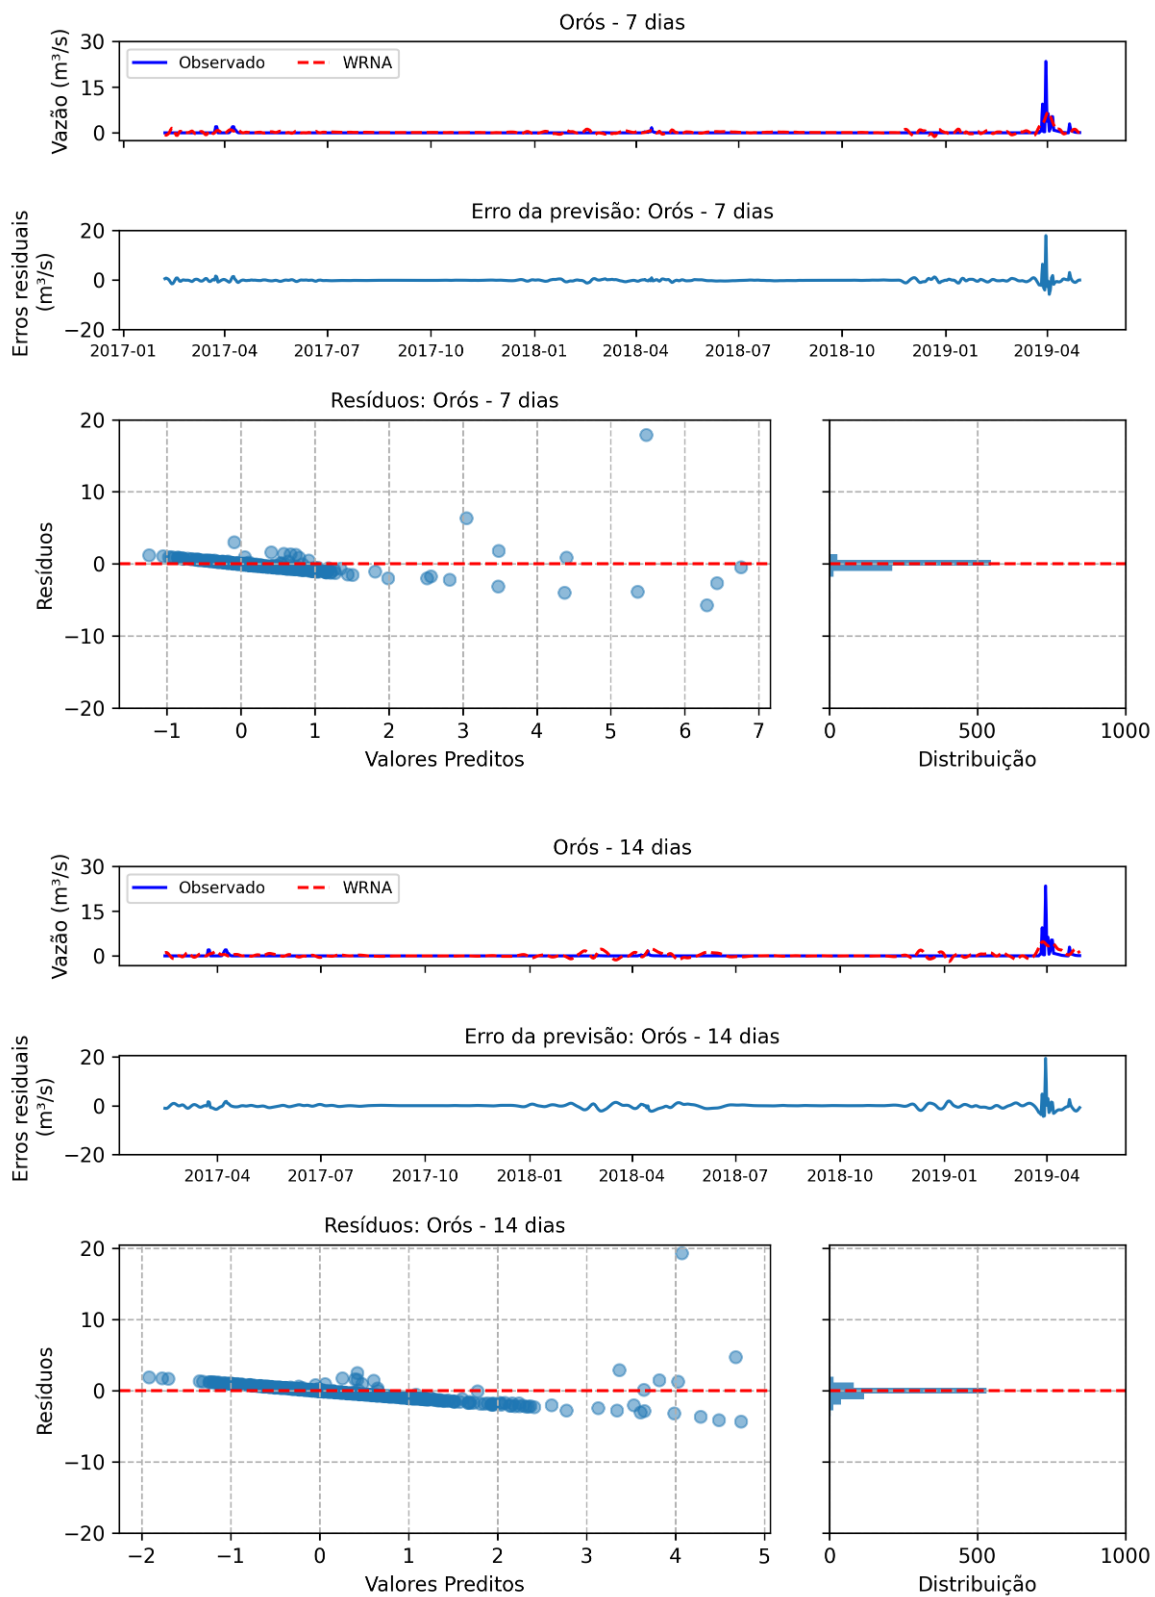
Fonte: Próprio autor

Figura 62 – Previsão WRNA - Castanhão 21 e 28 dias



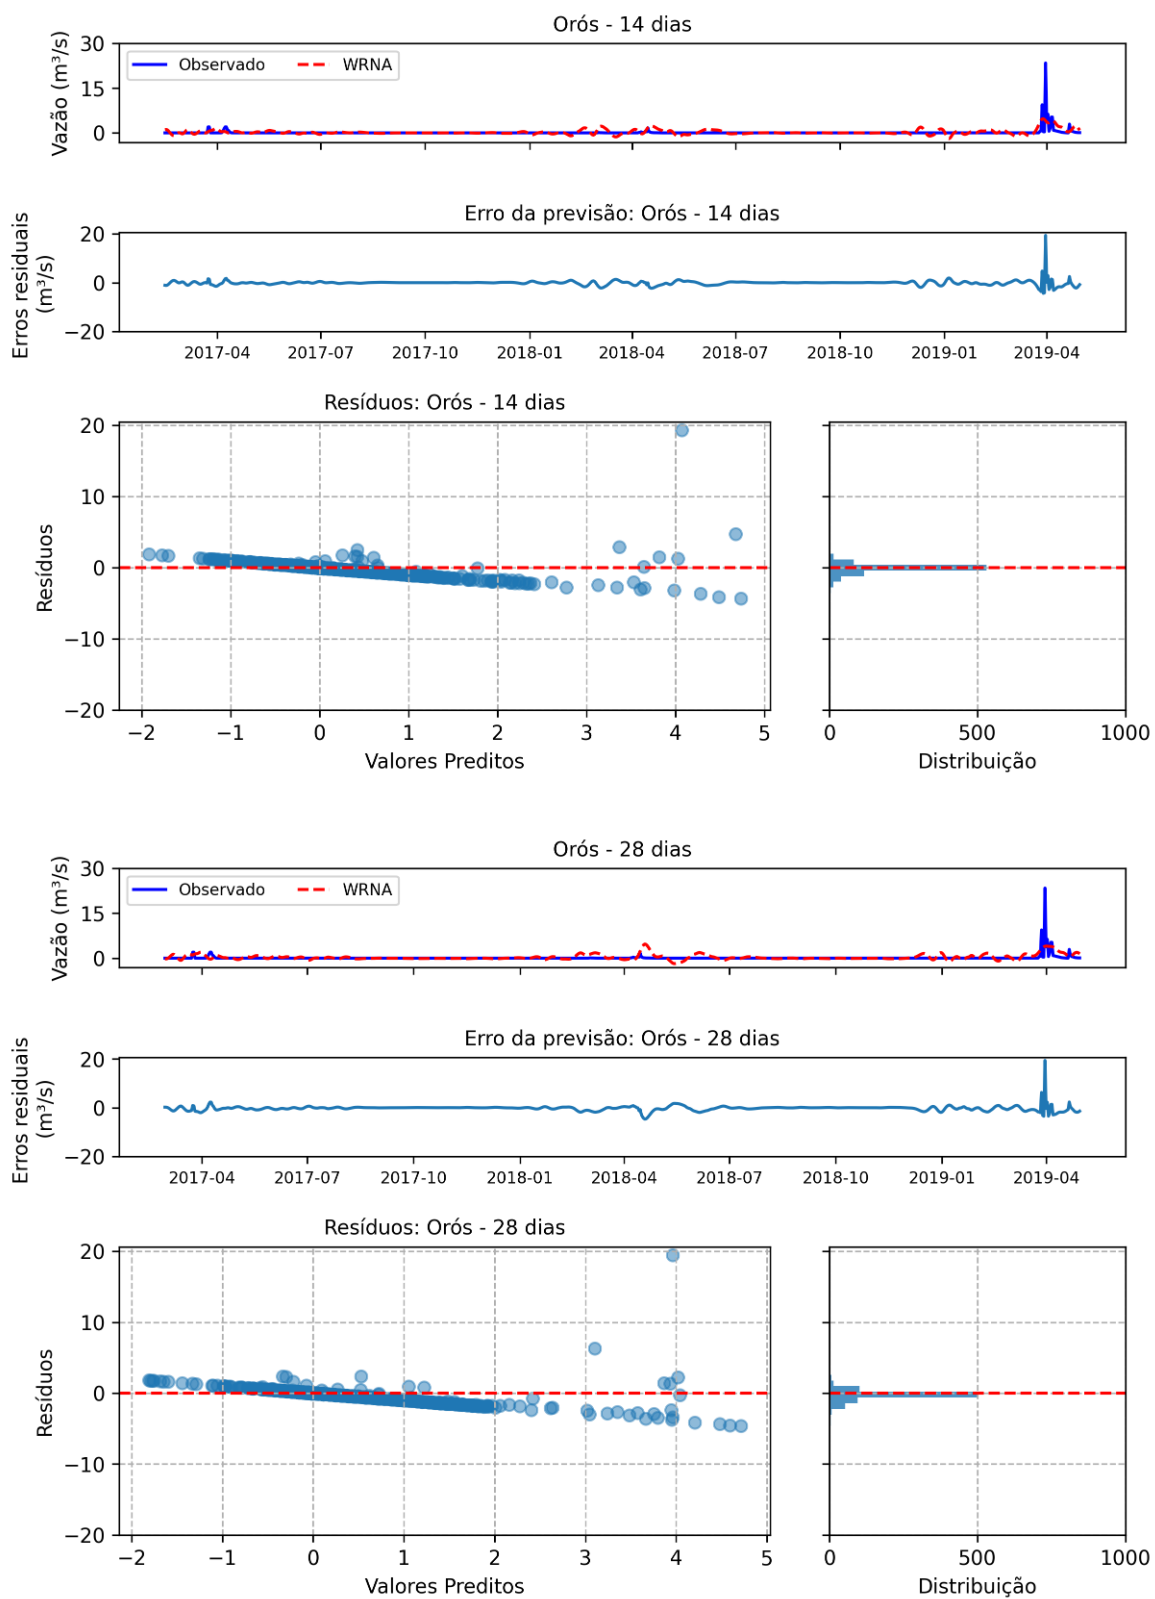
Fonte: Próprio autor

Figura 63 – Previsão WRNA - Orós 7 e 14 dias



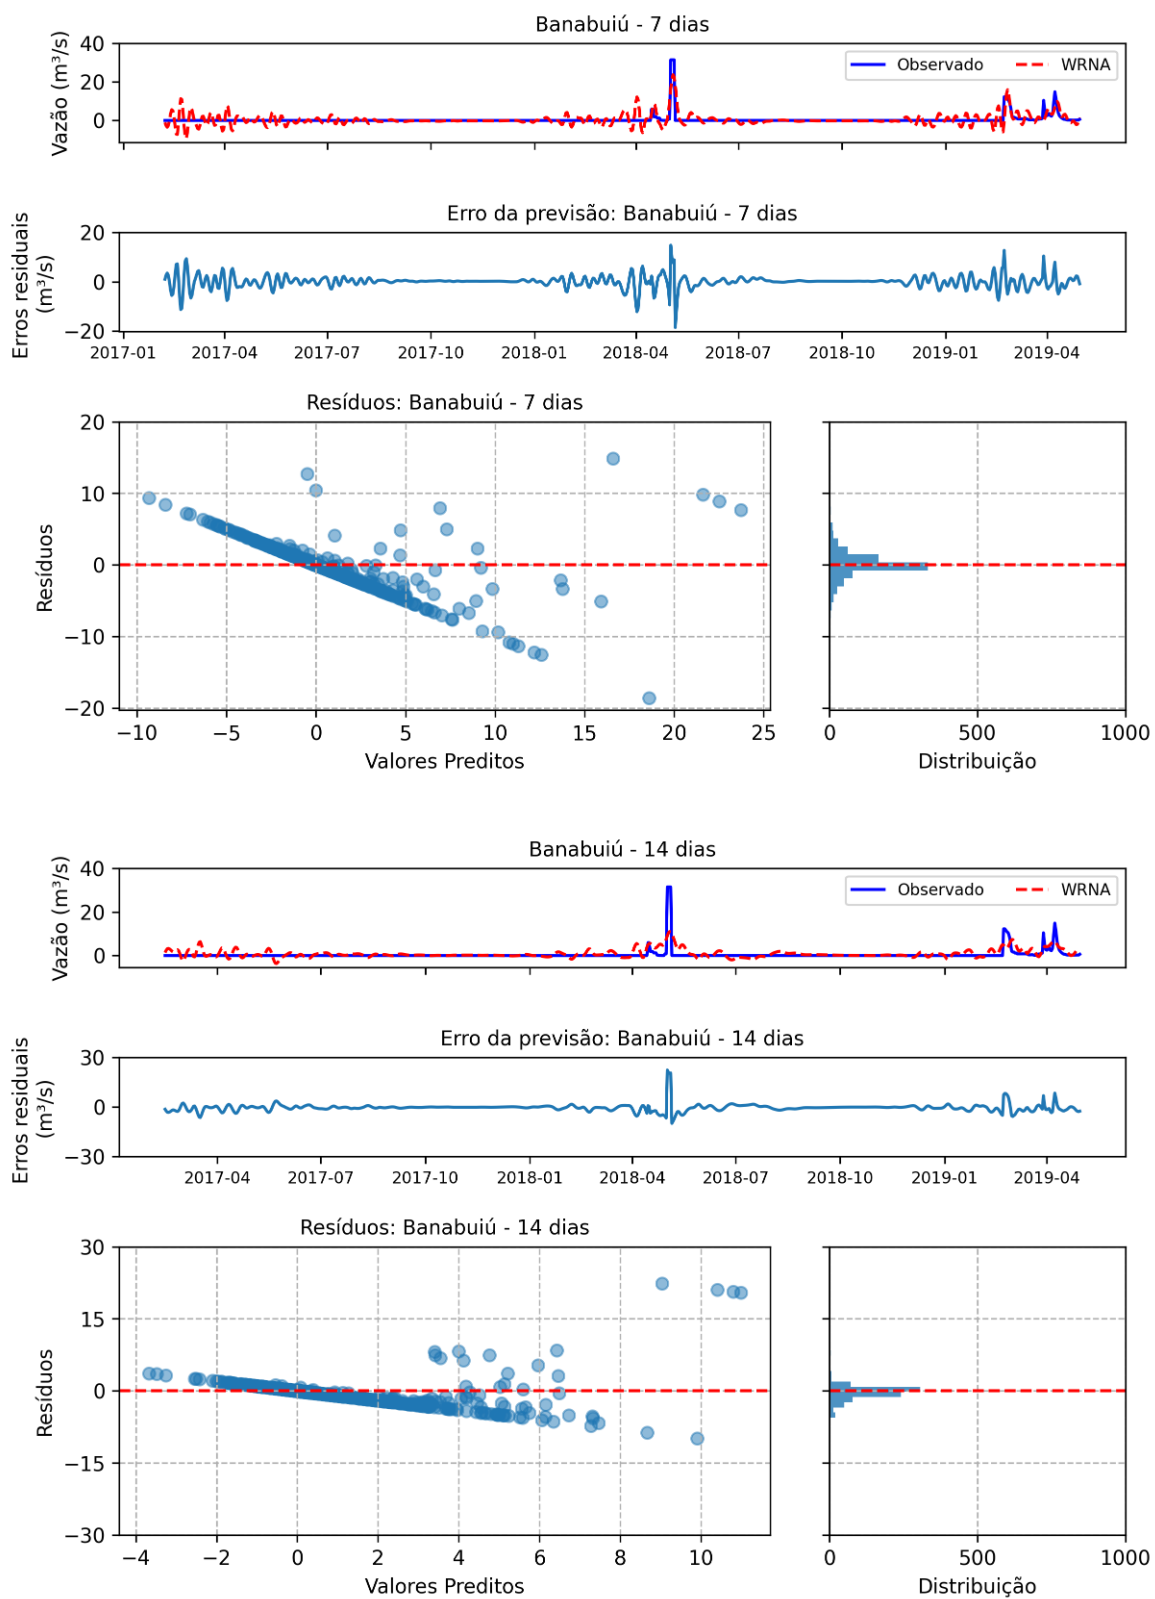
Fonte: Próprio autor

Figura 64 – Previsão WRNA - Orós 21 e 28 dias



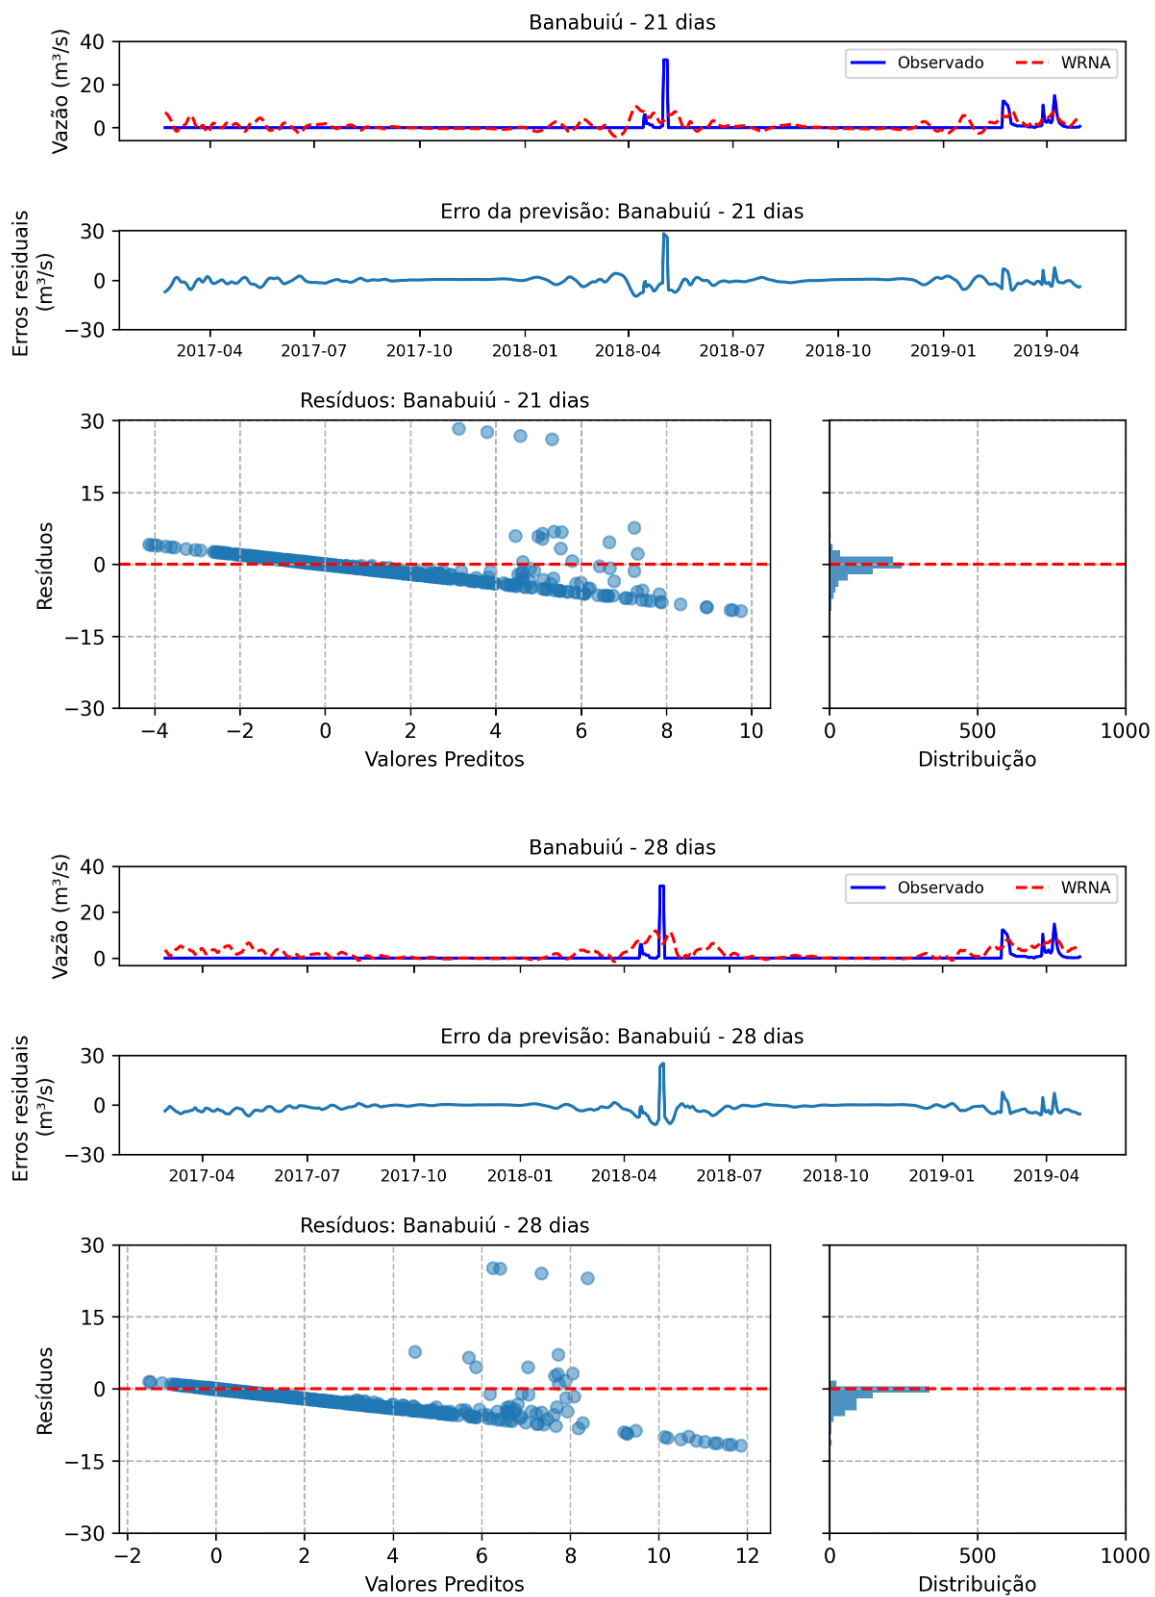
Fonte: Próprio autor

Figura 65 – Previsão WRNA - Banabuiú 7 e 14 dias



Fonte: Próprio autor

Figura 66 – Previsão WRNA - Banabuiú 21 e 28 dias



Fonte: Próprio autor

5.4 Conclusões

Apresentou-se a implementação e uma avaliação comparativa de dois modelos de redes neurais para previsão de vazões diárias em diferentes horizontes de previsão. Os resultados obtidos revelaram diferenças significativas entre os desempenhos dos modelos.

Inicialmente, foram testadas redes neurais tradicionais (RNA) em nove bacias hidrográficas, em que se observou um desempenho satisfatório para previsões de curto prazo (até 7 dias) nas bacias do Retiro Baixo, Três Marias e Sobradinho. Entretanto, à medida que o horizonte de previsão aumentou, os índices estatísticos, como o coeficiente de eficiência de *Nash* e a correlação, apresentaram queda considerável, indicando uma limitação na capacidade de previsão desses modelos.

Nas bacias do Xingó, Luiz Gonzaga e Paulo Afonso, os resultados alcançados pela RNA estiveram abaixo do esperado, evidenciando um baixo desempenho. O mesmo ocorreu nas bacias do Castanhão, Orós e Banabuiú, em que a ausência de dados durante longos períodos comprometeu a qualidade das previsões realizadas pela RNA.

Por outro lado, os modelos de redes neurais híbridas, baseados na combinação das *wavelets* com a rede *LSTM*, demonstraram resultados superiores. Esses modelos apresentaram uma maior capacidade de capturar os padrões existentes nas séries de vazão, inclusive os picos, resultando em previsões mais precisas. Além disso, os índices estatísticos não sofreram uma degradação significativa à medida que o horizonte de previsão aumentou.

Nas bacias de Três Marias e Sobradinho, a rede neural híbrida alcançou um coeficiente de eficiência de *Nash* próximo a 0,9 para previsões de 7 e 14 dias, com exceções pontuais. Isso demonstra a capacidade desse modelo em produzir previsões de alta qualidade nessas bacias.

A rede neural híbrida também apresentou melhoras significativas nas previsões para as bacias do Xingó, Luiz Gonzaga e Paulo Afonso. A capacidade de acompanhar a tendência das séries de vazão e a melhoria dos índices estatísticos foram evidentes em comparação com a RNA.

No entanto, é importante ressaltar que, nas bacias do Ceará (Orós, Banabuiú e Castanhão), embora tenha ocorrido melhorias sensíveis nas previsões realizadas pela rede neural híbrida, a falta de dados adequados impediu um desempenho ainda melhor.

Após uma análise mais aprofundada dos resultados e considerando estudos anteriores, constatou-se que a abordagem de avaliação, utilizando de uma só vez todo o conjunto de dados para determinar o *Nash* e as correlações, pode apresentar algumas limitações na avaliação do

desempenho de modelos de previsão hidrológica. Em certos casos, essa abordagem pode resultar em métricas de desempenho excessivamente otimistas, gerando valores elevados de *Nash* e da correlação.

No entanto, observou-se que a avaliação mensal dos modelos de previsão hidrológica oferece uma perspectiva mais precisa e realista do desempenho desses modelos. Ao agrupar os dados de vazão em intervalos mensais, é possível obter uma análise mais detalhada das características sazonais e das variações ao longo do tempo, permitindo uma compreensão mais aprofundada do comportamento dos modelos de previsão.

Desta forma, observa-se que os modelos híbridos oferecem um potencial considerável para aprimorar a gestão dos recursos hídricos. Com previsões mais precisas e confiáveis, é possível tomar decisões mais informadas e embasadas no que diz respeito ao planejamento e à operação de sistemas hídricos. Isso, por sua vez, contribui para uma utilização mais eficiente dos recursos disponíveis, otimizando a distribuição de água, o gerenciamento de secas, inundações e a tomada de medidas preventivas.

Além disso, esses resultados reforçam a importância da integração de diferentes técnicas e abordagens para enfrentar desafios complexos de previsão hidrológica. A combinação de *wavelets* e *LSTM* demonstrou ser uma estratégia promissora, permitindo a captura eficaz de padrões e tendências nas séries de vazão, mesmo em bacias com características heterogêneas. Isso ressalta a necessidade contínua de buscar abordagens inovadoras e integrativas para avançar no campo da previsão hidrológica.

6 COMPARATIVO DE DESEMPENHO

6.1 Introdução

No Capítulo 4, conduziu-se estudos com o propósito de calibrar o modelo hidrológico SMAP para as bacias hidrográficas analisadas. Os resultados obtidos mostraram-se favoráveis para as bacias dos reservatórios de Retiro Baixo, Três Marias, Sobradinho, Castanhão, Orós e Banabuiú. Através de índices estatísticos, constatou-se a eficácia da calibração realizada, indicando uma notável adaptação do modelo aos dados observados.

Posteriormente, no Capítulo 5, os esforços foram concentrados na implementação de um modelo de rede neural híbrida, o qual combina a técnica da transformada *wavelets* com a rede neural *LSTM*. Através dos índices estatísticos, foi possível constatar que as redes neurais híbridas apresentaram um notável poder de representação do comportamento das séries hidrológicas, mostrando-se capazes de prever picos e capturar variações da vazão em diferentes cenários.

Neste capítulo, serão realizadas análises comparativas de desempenho entre a WRNA e o SMAP em cenários que abrangem eventos de chuvas extremas e suas conseqüentes variações na vazão. Além disso, as previsões da WRNA serão comparadas com as previsões geradas pelos modelos PREVIVAZ (MACEIRA *et al.*, 1999) e CPINS (PAIVA; ACIOLI, 2007), disponibilizadas pelo Operador Nacional do Sistema Elétrico (ONS).

No Brasil, o ONS desempenha um papel crucial como órgão responsável pela coordenação e controle das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN). Suas atribuições abrangem diversas áreas, incluindo o monitoramento das vazões nos reservatórios que abrigam as hidrelétricas do país. O ONS utiliza e elabora periodicamente previsões de vazões naturais para os locais de aproveitamentos hidrelétricos dentro do SIN. Essas previsões têm o papel de subsidiar a tomada de decisão para o planejamento e a operação do setor eletroenergético. Elas são especialmente utilizadas no âmbito do Programa Mensal de Operação (PMO), com o propósito de promover o despacho centralizado das usinas de forma otimizada (ONS, 2015).

Desde janeiro de 2006, o ONS passou a utilizar modelos que incorporam informações de precipitação observada e prevista para aprimorar as previsões de vazões. Entre os modelos adotados pelo órgão, destacam-se o PREVIVAZ, o SMAP, o modelo baseado em lógica FUZZY e o CPINS. Essas ferramentas permitem a realização de previsões de vazões ao longo do ano para os diferentes subsistemas e bacias do SIN, abrangendo diversos horizontes de previsão.

6.2 Metodologia

Com o propósito de avaliar o desempenho do SMAP e da WRNA em situações hidrológicas caracterizadas por chuvas intensas, as quais têm um impacto significativo nos padrões de vazão das bacias hidrográficas, foram previamente identificados os períodos em que ocorreram eventos pluviométricos extremos.

Conforme realizado no Tópico 2.5, a identificação de eventos de chuvas extremas ocorreu ao calcular o percentil 95 para cada mês das bacias hidrográficas. Para cada mês, os dados de precipitação de toda a série histórica foram agrupados e o valor específico do percentil 95 foi calculado. Por exemplo, para a bacia de Três Marias, para o mês de janeiro, todas as chuvas ocorridas nesse período foram consideradas, e o valor correspondente do percentil 95 foi calculado. Dessa forma, foram identificados como eventos extremos, no mês de janeiro, em Três Marias, as chuvas que excederam esse valor específico. Esse procedimento foi repetido para todos os meses em todas as bacias.

Dentre os eventos extremos identificados, optou-se por escolher aqueles que ocorreram dentro da estação chuvosa, em períodos que coincidiram tanto com os horizontes de previsão utilizados pela abordagem WRNA quanto com os períodos de validação do modelo hidrológico SMAP. Os períodos analisados correspondem a 25/05/2015 a 01/03/2015 para Três Marias e Sobradinho, 11/01/2000 a 15/02/2000 para Xingó e 13/04/2009 a 18/05/2009 para a bacia do Castanhão.

Os parâmetros empregados nas previsões conduzidas pelo modelo SMAP correspondem àqueles previamente calibrados e detalhados no Capítulo 4. Adicionalmente, os dados de precipitação passados ao modelo, correspondem a média das previsões originadas dos modelos numéricos analisados no Capítulo 3. As previsões geradas pelo SMAP são então comparadas com as estimativas da WRNA para o período de análise.

No Capítulo 2, constatou-se que as bacias de Retiro Baixo, Três Marias e Sobradinho exibiram padrões hidrológicos bastante similares, assim como as bacias de Luiz Gonzaga, Paulo Afonso e Xingó, e também as bacias de Castanhão, Banabuiú e Orós. Em virtude dessa similaridade de comportamento e da disponibilidade de dados hidrológicos de alta qualidade, optou-se por incluir, nas análises das previsões em períodos de eventos extremos, somente as bacias de Três Marias, Sobradinho, Xingó e Castanhão.

Para avaliar o desempenho da previsão da WRNA em comparação com a utilizada pelo ONS, colheu-se estatísticas referentes às previsões realizadas pelo ONS. Esses dados foram

obtidos a partir do relatório da análise de desempenho de previsão de vazão conduzida pelo ONS e estão disponíveis para acesso em sintegre.ons.org.br. As previsões realizadas pelo órgão, são referentes as vazões naturais afluentes a todos os aproveitamentos do SIN. Essas previsões são feitas semanalmente, no dia imediatamente anterior à elaboração do PMO, e passam por revisões semanais.

No processo operacional da ONS, os modelos são responsáveis por realizar as previsões de vazões diárias, que por sua vez são utilizadas para calcular as vazões naturais afluentes médias ao longo da semana em curso. Com base nessas estimativas semanais, o modelo PREVIVAZ é empregado para elaborar as previsões de vazões para todas as semanas do mês abrangido pelo PMO, incluindo suas revisões.

Nesta análise, as previsões da WRNA serão comparadas com as previsões realizadas pela ONS para as bacias de Retiro Baixo, Três Marias, Sobradinho e Luiz Gonzaga. As previsões da ONS para Sobradinho e Itaparica são provenientes do modelo CPINS, enquanto as previsões para Retiro Baixo e Três Marias são feitas pelo modelo PREVIVAZ. As estimativas compreendem médias semanais de vazão natural, projetadas com antecedência de uma, duas e três semanas, referentes ao primeiro trimestre dos anos de 2014 e 2015. A seleção do período de análise foi realizada visando assegurar a sincronia entre o intervalo de previsão da WRNA e os dados disponibilizados pelo ONS. A escolha do primeiro trimestre decorre do fato de que as maiores vazões nessas bacias acontecem nos primeiros meses do ano.

O desempenho dos modelos foi avaliado através do coeficiente de correlação de Pearson (r), do índice de eficiência de *Nash-Sutcliffe* (*Nash*) e do Erro Médio Percentual Absoluto (*MAPE*). Uma descrição detalhada dos dois primeiros índices pode ser encontrada no Tópico 3.3 deste trabalho.

O *MAPE* (Equação 6.1) representa a média da diferença absoluta entre os valores previstos e observados, expressa em porcentagem dos valores observados, podendo variar no intervalo $(\infty, 0]$, sendo que o valor $MAPE = 0$ corresponde a previsões perfeitas no período.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{O_t - P_t}{O_t} \right| \quad (6.1)$$

em que n é número de intervalos de tempo, O_t é vazão observada no intervalo de tempo t , e P_t representa a vazão prevista no intervalo de tempo t .

6.3 Resultados

A Tabela 21 apresenta os indicadores estatísticos de desempenho dos modelos SMAP e WRNA para os períodos em que foram identificados eventos de chuvas extremas. Os resultados mostram uma vantagem significativa para o modelo WRNA em relação ao modelo SMAP. Em todas as bacias analisadas, a WRNA demonstrou uma melhor habilidade em representar de forma mais precisa as vazões observadas. Os coeficientes de eficiência de *Nash* mais próximos de 1 mostram que a WRNA obteve um desempenho mais próximo do ideal, sugerindo maior acurácia nas previsões. Além disso, a WRNA exibiu uma correlação mais robusta entre as vazões previstas e observadas, evidenciando sua capacidade superior em capturar a relação entre essas variáveis durante eventos extremos. Notavelmente, ao apresentar valores de *Pbias* próximos de zero em todas as bacias, a WRNA também revelou uma menor tendência de superestimar ou subestimar as vazões, confirmando sua maior precisão e confiabilidade em comparação com o SMAP.

Tabela 21 – Indicadores de desempenho


Bacia	SMAP			WRNA		
	<i>Nash</i>	<i>r</i>	<i>Pbias</i> (%)	<i>Nash</i>	<i>r</i>	<i>Pbias</i> (%)
Três Marias	-0.935	0.814	-54.008	0.931	0.965	-0.254
Sobradinho	-0.41	0.51	-57.679	0.972	0.987	-1.914
Xingó	-0.599	0.171	-82.406	0.844	0.922	2.123
Castanhão	0.61	0.881	17.276	0.863	0.932	-4.447

Fonte: Próprio autor

Nas Figuras 67 a 70 são apresentados os hidrogramas observados e calculados pelos modelos nas sub-bacias estudadas durante os eventos analisados. Adicionalmente, é exibida a série de dados de precipitação observadas, juntamente com a média das precipitações calculadas pelos modelos, acumuladas em um período de 24 horas. A análise das Figuras corroboram os resultados encontrados na análise dos indicadores estatísticos, evidenciando o melhor desempenho da WRNA em comparação ao SMAP.


Observa-se que a WRNA apresentou uma notável sensibilidade aos eventos de chuvas extremas estudados, refletindo de maneira consistente as variações das vazões causadas pelas chuvas intensas. Por outro lado, o SMAP mostrou-se menos eficiente em capturar essas flutuações hidrológicas, apresentando limitações, principalmente nas bacias de Sobradinho e Xingó.

Figura 67 – Bacia de Três Marias




Fonte: Próprio autor.

Figura 68 – Bacia de Sobradinho




Fonte: Próprio autor.

Figura 69 – Bacia do Xingó



Fonte: Próprio autor.



Fonte: Próprio autor.

O modelo SMAP apresentou seu desempenho mais notável nas previsões para a bacia do Castanhão. Nesse cenário, o coeficiente de eficiência *Nash* atingiu a marca de 0,61, com uma correlação próxima a 0,88 e um índice *Pbias* de 17,28%. Nas bacias de Três Marias e Sobradinho, apesar de terem sido observados valores consistentes dos indicadores estatísticos durante o processo de calibração e validação (Capítulo 4), o SMAP não conseguiu capturar os eventos extremos, mostrando eficácia apenas ao retratar o comportamento geral das séries de vazão nessas áreas, como demonstrado anteriormente.


Nas Figuras 71 e 72, são apresentados os índices de desempenho *Nash* e *MAPE* para as previsões realizadas pela WRNA e pelo ONS nas bacias de Três Marias, Retiro Baixo, Sobradinho e Luiz Gonzaga. Esses índices representam a comparação entre as médias semanais de vazão natural observadas e as médias semanais de vazão natural previstas com antecedência de uma, duas e três semanas para o primeiro trimestre do ano de 2015.

Com relação as previsões realizadas para Retiro Baixo e Três Marias, observa-se que a WRNA apresentou um desempenho superior em relação as previsões realizadas pelo ONS em todos os horizontes de previsão. Os valores de *Nash* para a WRNA foram muito próximos de um, indicando uma boa concordância entre as previsões e os dados observados. Já os modelos utilizados pela ONS registrou valores negativos de *Nash* em Retiro baixo, sugerindo uma menor precisão nas previsões. O mesmo padrão foi observado para o índice *MAPE*, onde a WRNA obteve valores menores em comparação com as previsões realizadas pela ONS.

Na bacia de Sobradinho, tanto a WRNA quanto o ONS apresentaram resultados favoráveis em termos de concordância com os dados observados. Ambos os modelos conseguiram


capturar adequadamente os padrões de vazão para os diferentes horizontes de previsão. No entanto, observou-se que o ONS teve um desempenho um pouco melhor nas previsões realizadas com uma semana de antecedência, enquanto a WRNA obteve um desempenho ligeiramente superior para previsões com duas e três semanas à frente.

Figura 71 – Avaliação de desempenho: vazões médias semanais (2015)



Fonte: Próprio autor.

Figura 72 – Avaliação de desempenho: vazões médias semanais (2015)




Fonte: Próprio autor.

Quanto à bacia de Luiz Gonzaga, ambos os modelos também obtiveram resultados satisfatórios em geral, com boa concordância entre as previsões e os dados observados. Novamente, o ONS apresentou um melhor desempenho nas previsões para uma e duas semanas de antecedência, enquanto a WRNA teve um desempenho superior para previsões realizadas com três semanas antecedência.

Outro aspecto relevante é que os índices de desempenho da WRNA, em todas as bacias analisadas, não sofreram grandes flutuações quando as previsões foram realizadas para horizontes mais distantes (2 e 3 semanas), fato este que não foi observado nas previsões da ONS. Essa consistência nas métricas pode indicar uma maior robustez da WRNA em previsões de longo prazo, o que é um aspecto relevante para a confiabilidade das projeções.


Nas Figuras 73 e 74 são apresentadas as mesmas avaliações das Figuras 71 e 72, porém para o primeiro trimestre de 2014. Verifica-se que nas regiões das bacias de Três Marias e Retiro Baixo, a WRNA exibiu, mais uma vez, uma performance superior em comparação às projeções realizadas pelo ONS. No caso de Sobradinho, as estimativas provenientes da WRNA e do ONS apresentaram desempenhos equiparáveis. Em contraste, na bacia de Luiz Gonzaga, a WRNA alcançou uma performance inferior à apresentada pelo ONS.

Figura 73 – Avaliação de desempenho: vazões médias semanais (2014)



Fonte: Próprio autor.

Figura 74 – Avaliação de desempenho: vazões médias semanais (2014)



Fonte: Próprio autor.

6.4 Conclusões

A análise comparativa de desempenho entre a WRNA e o SMAP durante períodos de chuvas intensas revelou uma clara vantagem da WRNA sobre o SMAP. Os resultados evidenciaram que a WRNA possui uma habilidade superior em representar com precisão as vazões observadas, o que se refletiu em valores consistentes do coeficiente de eficiência de *Nash* e uma correlação mais robusta entre as vazões previstas e observadas. Além disso, a WRNA apresentou uma menor propensão a superestimar ou subestimar as vazões, demonstrando maior acurácia em suas estimativas.

Destaca-se adicionalmente a habilidade dos modelos numéricos empregados na previsão das precipitações em representar os eventos de chuvas extremas identificados nesta análise. Foi observado que, à exceção das precipitações registradas na bacia de Xingó, o aumento das precipitações foi capturado pela média das previsões dos modelos. Uma análise mais detalhada do desempenho desses modelos em capturar eventos extremos surge como uma sugestão para futuras investigações.

As análises comparativas entre as previsões realizadas pela WRNA e pelo ONS, evidenciaram que a WRNA apresentou um desempenho global superior em relação ao modelo

operacional do ONS. A diferença de desempenho foi especialmente significativa nas bacias de Três Marias e Retiro Baixo, onde a WRNA demonstrou maior capacidade de representar de forma precisa as vazões observadas. Além disso, a WRNA também se mostrou mais eficiente nas previsões de longo prazo, mantendo índices de desempenho mais estáveis em comparação com o ONS.

Os resultados obtidos ressaltam a significativa relevância e potencial da WRNA no contexto da modelagem hídrica e na tomada de decisão. O modelo aqui apresentado revela-se uma ferramenta promissora para enfrentar os desafios complexos e dinâmicos da hidrologia, tornando-se uma aliada valiosa na gestão sustentável dos recursos hídricos.

7 CONCLUSÕES E RECOMENDAÇÕES

O foco central deste estudo foi o desenvolvimento de modelos de previsão utilizando Redes Neurais Artificiais, empregando uma abordagem de pré-processamento fundamentada na aplicação de *wavelets*. O objetivo principal consistiu em estimar as vazões em uma escala sub-sazonal, considerando as sub-bacias hidrográficas do rio São Francisco, bem como três sub-bacias situadas no Estado do Ceará.

Adicionalmente, foram conduzidas análises preliminares a respeito da variabilidade das precipitações em escala sub-sazonal na região de estudo. Além disso, realizou-se uma avaliação do desempenho de modelos numéricos desenvolvidos por quatro reconhecidos centros de pesquisa climática, os quais realizam previsões de precipitação em escala sub-sazonal. Os estudos também contemplaram a calibração do modelo hidrológico SMAP.

Os resultados obtidos revelaram a presença de flutuações de curta duração e alta frequência durante o período chuvoso, demonstrando uma consistente variabilidade sub-sazonal em todas as regiões analisadas. Verificou-se que a Oscilação Madden-Julian (OMJ) exerce uma influência significativa na variabilidade das precipitações, e sua interação com o El Niño-Oscilação Sul (ENOS) revelou-se relevante em diferentes fases da OMJ. Essa interação resultou em uma diminuição na ocorrência de eventos extremos de chuva em algumas bacias, ao passo que em outras houve um aumento na proporção de chuvas extremas.

Foi observado padrões distintos nas diferentes fases da OMJ em relação às precipitações. Durante a fase 2 e 8 da OMJ, verificou-se um aumento significativo na ocorrência de chuvas em praticamente todas as bacias. Por outro lado, nas bacias de Retiro Baixo, Três Marias e Sobradinho, as fases 4 e 5 apresentaram anomalias negativas significativas. Já nas bacias do Luiz Gonzaga, Paulo Afonso, Xingó e Jaguaribe, foram registradas anomalias negativas significativas durante a fase 6. Observou-se ainda que em períodos de ocorrência de eventos de El Niño e La Niña, os padrões de anomalias observados durante o ENOS sem a presença da OMJ podem ser amplificados quando o ENOS e a OMJ ocorrem simultaneamente.

A análise do desempenho das previsões de precipitação realizadas pelos modelos numéricos revelou que os modelos CFSv2 e GEFSv2 demonstraram um desempenho superior em todas as bacias e horizontes de previsão avaliados. Por outro lado, constatou-se que os modelos do CPTEC e ESRL apresentaram limitações em seu desempenho, principalmente ao simular a precipitação acumulada nas bacias do Castanhão, Banabuiú e Orós.

A calibração do modelo SMAP para simular vazões nas bacias do São Francisco e

Jaguaribe registrou êxito em Retiro Baixo, Três Marias, Sobradinho, Castanhão, Banabuiú e Orós. Nessas áreas, o modelo demonstrou eficácia capturando as variações sazonais e representando de forma eficiente os picos de vazão. Entretanto, o modelo revelou limitações nas simulações das bacias de Luiz Gonzaga, Paulo Afonso e Xingó, ressaltando a importância de abordagens mais específicas para lidar com padrões hidrológicos complexos, característicos dessas bacias.

Por fim, os modelos de redes neurais híbridas, que combinam a técnica de *wavelets* com a rede *LSTM*, mostraram desempenho superior em relação às redes neurais que não incorporaram a abordagem das *wavelets* para a previsão de vazões em escala sub-sazonal. As redes neurais híbridas demonstraram uma capacidade aprimorada de capturar os padrões existentes nas séries de vazão, incluindo picos e variações bruscas, resultando em previsões mais precisas e confiáveis. Além disso, os índices estatísticos utilizados para avaliar o desempenho dos modelos não apresentaram grandes degradações à medida que o horizonte de previsão foi estendido, especialmente nas bacias de Retiro Baixo, Três Marias e Sobradinho. Indicando que os modelos híbridos de redes neurais foram capazes de manter sua acurácia e habilidade preditiva mesmo para períodos de previsão mais distantes.

A utilização da rede neural híbrida também resultou em melhorias significativas nas previsões para as bacias do Xingó, Luiz Gonzaga e Paulo Afonso. Foi observada uma maior capacidade de acompanhar as tendências das séries de vazão, bem como uma melhoria nos índices estatísticos em comparação com a RNA convencional. No entanto, a qualidade dos dados disponíveis afetou o desempenho nas bacias do Orós, Banabuiú e Castanhão.

A análise comparativa entre a WRNA e o SMAP durante períodos chuvosos intensos apontou para uma superioridade da WRNA, que se destacou por resultados mais precisos, refletidos em coeficientes de eficiência de *Nash* consistentes e forte correlação entre previsões e observações de vazão. A WRNA também minimizou discrepâncias e apresentou um desempenho superior aos modelos preditivos utilizados pelo ONS nas bacias de Três Marias e Retiro Baixo, ressaltando sua capacidade de representação hidrológica e seu potencial para a gestão sustentável dos recursos hídricos.

Os resultados destacam a relevância deste estudo para o entendimento das características hidrológicas e climáticas da região, bem como para o aprimoramento dos modelos de previsão de vazões. A aplicação desses modelos pode auxiliar na tomada de decisões relacionadas à gestão de recursos hídricos, planejamento agrícola e prevenção de desastres naturais, contribuindo para a sustentabilidade e resiliência das comunidades locais.

Recomenda-se a realização de estudos adicionais para ampliar a análise às demais bacias hidrográficas da região, acompanhados de uma análise detalhada do desempenho durante a estação chuvosa. Além disso, é oportuno explorar abordagens de modelagem alternativas, como redes neurais convolucionais e modelos de aprendizado de máquina mais sofisticados, visando aprimorar ainda mais a precisão das previsões.

Outra sugestão é testar a eficácia da metodologia WRNA na previsão de vazão em escalas horárias, mensais e anuais. Complementarmente, sugere-se considerar a incorporação das previsões de precipitação advindas dos modelos numéricos nos processos das redes neurais, com o intuito de simplificar a operacionalização deste procedimento em sistemas voltados para a gestão de recursos hídricos.

REFERÊNCIAS

- ADAMOWSKI, J.; CHAN, H. F. A wavelet neural network conjunction model for groundwater level forecasting. **Journal of Hydrology**, Elsevier, v. 407, n. 1-4, p. 28–40, 2011.
- ADAMOWSKI, J.; CHAN, H. F.; PRASHER, S. O.; OZGA-ZIELINSKI, B.; SLIUSARIEVA, A. Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in montreal, canada. **Water Resources Research**, Wiley Online Library, v. 48, n. 1, 2012.
- AGGARWAL, C. C. *et al.* Neural networks and deep learning. **Springer**, Springer, v. 10, n. 978, p. 3, 2018.
- AKSOY, H.; DAHAMSHEH, A. Artificial neural network models for forecasting monthly precipitation in jordan. **Stochastic Environmental Research and Risk Assessment**, Springer, v. 23, n. 7, p. 917–931, 2009.
- ALVES, J. M. B.; CAMPOS, J. N. B.; SOUZA, E. d.; REPELLI, C. A. Produção agrícola de subsistência no estado do ceará com ênfase aos anos de ocorrência de el niño e la niña. **Revista Brasileira de Agrometeorologia**, v. 6, n. 2, p. 249–256, 1998.
- ALVES¹, L. M.; MARENGO¹, J. A.; JÚNIOR¹, H. C.; CASTRO¹, C. Início da estação chuvosa na região sudeste do brasil: Parte 1-estudos observacionais. 2005.
- AMARI, S. *et al.* **The handbook of brain theory and neural networks**. [S.l.]: MIT press, 2003.
- ANDREOLI, R. V.; KAYANO, M. T.; GUEDES, R. L.; OYAMA, M. D.; ALVES, M. A. S. A influência da temperatura da superfície do mar dos oceanos pacífico e atlântico na variabilidade de precipitação em fortaleza. **Revista Brasileira de Meteorologia**, v. 19, n. 3, p. 337–344, 2004.
- AQIL, M.; KITA, I.; YANO, A.; NISHIYAMA, S. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. **Journal of hydrology**, Elsevier, v. 337, n. 1-2, p. 22–34, 2007.
- ARAÚJO, C. B. C. d.; NETO, S. D.; FILHO, F. d. A. S. Previsão de vazões para o açude orós/ce a partir de dados hidrometeorológicos utilizando perceptrons. **Revista Brasileira de Meteorologia**, v. 30, n. 1, p. 37–46, 2005.
- ARAÚJO, R. G.; ANDREOLI, R. V.; CANDIDO, L. A.; KAYANO, M. T.; SOUZA, R. A. F. d. A influência do evento el niño-oscilação sul e atlântico equatorial na precipitação sobre as regiões norte e nordeste da américa do sul. **Acta Amazonica**, SciELO Brasil, v. 43, p. 469–480, 2013.
- BALLINI, R.; SOARES, S.; ANDRADE, M. G. Previsão de vazões médias mensais usando redes neurais nebulosas. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, SciELO Brasil, v. 14, n. 3, p. 680–693, 2003.
- BELAYNEH, A.; ADAMOWSKI, J.; KHALIL, B.; OZGA-ZIELINSKI, B. Long-term spi drought forecasting in the awash river basin in ethiopia using wavelet neural network and wavelet support vector regression models. **Journal of Hydrology**, Elsevier, v. 508, p. 418–429, 2014.

- BETTENCOURT, P.; FULGÊNCIO, C.; GRADE, M.; ALCOBIA, S.; MONTEIRO, J. P.; OLIVEIRA, R.; LEITÃO, J. C.; LEITÃO, P. C.; FERNANDES, P. A.; SOUSA, S. de *et al.* Plano de recursos hídricos da bacia hidrográfica do rio são francisco. **Recursos Hídricos**, 2016.
- BJERKNES, V. Das problem der wettvorhersage, betrachtet vom standpunkte der mechanik und der physik. **Meteor. Z.**, v. 21, p. 1–7, 1904.
- BOARD, O. S.; ENGINEERING, N. A. of S.; MEDICINE *et al.* **Next generation earth system prediction: strategies for subseasonal to seasonal forecasts**. [S.l.]: National Academies Press, 2016.
- BORELLA, L. d. C.; BORELLA, M. R. d. C.; CORSO, L. L. Climate analysis using neural networks as supporting to the agriculture. **Gestão & Produção**, SciELO Brasil, v. 29, 2022.
- BORMANN, H.; BREUER, L.; GRÄFF, T.; HUISMAN, J. A. Analysing the effects of soil properties changes associated with land use changes on the simulated water balance: A comparison of three hydrological catchment models for scenario analysis. **Ecological modelling**, Elsevier, v. 209, n. 1, p. 29–40, 2007.
- BRAVO, J. M.; PEDROLLO, O. C.; COLLISCHONN, W.; PAZ, A. R. d.; UVO, C. B. Previsões de curto prazo de vazão afluente ao reservatório de furnas utilizando redes neurais artificiais. **Rbrh: revista brasileira de recursos hídricos**, v. 13, n. 2, p. 77–88, 2008.
- CALDEIRA, T. L.; OLIVEIRA, V. A. de; STEINMETZ, A. A.; VIOLA, M. R.; BESKOW, S. Modelagem hidrológica determinística chuva-vazão em bacias hidrográficas: Uma abordagem introdutória. **Revista Brasileira de Engenharia e Sustentabilidade**, v. 5, n. 1, p. 22–32, 2018.
- CANNAS, B.; FANNI, A.; SEE, L.; SIAS, G. Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. **Physics and Chemistry of the Earth, Parts A/B/C**, Elsevier, v. 31, n. 18, p. 1164–1171, 2006.
- CARDOSO, G. B. B.; MARTINS, E. S. P. R.; FILHO, F. d. A. d. S. Uso de otimização/simulação e previsão de aflúências na operação tática dos reservatórios do sistema jaguaribe-metropolitano-ce. *Revista Brasileira de Recursos Hídricos*, 2006.
- CASTILLO, J. E.; OLIVEIRA, M.; AYLTON, P.; ODIM, M. **Introdução ao mundo das wavelets**. [S.l.]: SBMAC, 2012. v. 1.
- CASTRO, E. S.; ALVES, J. M. B.; SILVA, E. M. d.; CAMPOS, J. N.; ALVES, A. O. Previsão de temperatura da superfície do mar (tsm) no atlântico tropical com uso de redes neurais. **Revista Brasileira de Meteorologia**, SciELO Brasil, v. 35, p. 505–515, 2020.
- CAVALCANTI, I. F. **Tempo e clima no Brasil**. [S.l.]: Oficina de textos, 2016.
- CBHSF, C. d. B. H. d. Rio são francisco. **Plano de Recursos**, 2016.
- CEARÁ, A. L. Caderno regional da sub-bacia do alto jaguaribe. **Conselho de Altos Estudos e Assuntos Estratégicos. Fortaleza: INESP**, 2009.
- CEARÁ, A. L. Caderno regional da sub-bacia do médio jaguaribe. **Conselho de Altos Estudos e Assuntos Estratégicos. Fortaleza: INESP**, 2009.
- COLLINS, M. Climate change and enso: Take 2. 2014.

COLLISCHONN, W.; ALLASIA, D.; SILVA, B. C. D.; TUCCI, C. E. The mgb-iph model for large-scale rainfall—runoff modelling. **Hydrological Sciences Journal**, Taylor & Francis, v. 52, n. 5, p. 878–895, 2007.

COLLISCHONN, W.; TUCCI, C. E. M. Ajuste multiobjetivo dos parâmetros de um modelo hidrológico. **Rbrh: revista brasileira de recursos hídricos. Porto Alegre, RS: ABRH. Vol. 8, n. 3 (jul./set. 2003), p. 27-39**, 2003.

CUNHA, G. R. da; PIRES, J. L. F.; DALMAGO, G. A.; SANTI, A.; PASINATO, A.; SILVA, A. A. G. da; ASSAD, E. D.; ROSA, C. El niño/la niña-oscilação sul e seus impactos na agricultura brasileira: fatos, especulações e aplicações. *Revista Plantio Direto, Passo Fundo*, v. 20, n. 121, p. 18-22, jan./fev. 2011., 2011.

DANTAS, D.; LUZ, T. M. O.; SOUZA, M. J. H. de; BARBOSA, G. P.; CUNHA, E. G. S. Uso de redes neurais artificiais na previsão da precipitação de períodos chuvosos. **Revista Espinhaço**, 2016.

DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. **IEEE transactions on information theory**, Ieee, v. 36, n. 5, p. 961–1005, 1990.

DIXON, B. Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a gis-based sensitivity analysis. **Journal of hydrology**, Elsevier, v. 309, n. 1-4, p. 17–38, 2005.

FIGUEIREDO, K.; BARBOSA, C. R. H.; CRUZ, A.; VELLASCO, M.; PACHECO, M. A. C.; CONTRERAS, R. J.; BARROS, M.; SOUZA, R. C.; MARQUES, V.; DUARTE, U. M. *et al.* Modelo de previsão de vazão com informação de precipitação utilizando redes neurais. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 69–82, 2007.

FILHO, F. d. A. de S. **Memórias do seminário natureza e sociedade nos Semi-Áridos**. [S.l.]: Banco do Nordeste do Brasil: Fundação Cearense de Meteorologia e Recursos . . . , 2006.

FILHO, G. M. M.; ANDRADE, R. S.; ZUKOWSKI, J. C.; MAGALHÃES, L. L. Modelos hidrológicos: conceitos e aplicabilidades. **Revista de Ciências Ambientais**, v. 6, n. 2, p. 35–47, 2013.

FREIRE, P. K. d. M. M. *et al.* O uso da transformada wavelet na previsão de vazão. Universidade Federal da Paraíba, 2012.

FREIRE, P. K. d. M. M.; SANTOS, C. A. G.; SILVA, G. B. L. da. Analysis of the use of discrete wavelet transforms coupled with ann for short-term streamflow forecasting. **Applied Soft Computing**, Elsevier, v. 80, p. 494–505, 2019.

GLANTZ, M.; KATZ, R.; NICHOLLS, N. **Teleconnections linking worldwide climate anomalies**. [S.l.]: Cambridge University Press, 1991.

GOMES, L. F. C.; MONTENEGRO, S.; VALENÇA, M. Modelo baseado na técnica de redes neurais para previsão de vazões na bacia do rio são francisco. **Revista Brasileira de Recursos Hídricos**, v. 15, n. 1, p. 05–15, 2010.

GOTTSCHALCK, J.; KOUSKY, V.; HIGGINS, W.; L'HEUREUX, M. Madden julian oscillation (mjo) i. definition: The mjo is an intraseasonal fluctuation or “wave” occurring in the global tropics. the mjo is responsible for the majority of weather variability in these regions and results in variations in several important atmospheric and oceanic parameters which include both lower-and upper-level wind speed and direction. 2004.

GREEN, C.; TOMER, M.; LUZIO, M. D.; ARNOLD, J. Hydrologic evaluation of the soil and water assessment tool for a large tile-drained watershed in iowa. **Transactions of the ASABE**, American Society of Agricultural and Biological Engineers, v. 49, n. 2, p. 413–422, 2006.

GUILHON, L. G. F.; ROCHA, V. F.; MOREIRA, J. C. Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 3, p. 13–20, 2007.

GUIMARÃES, B. S.; COELHO, C. A.; WOOLNOUGH, S. J.; KUBOTA, P. Y.; BASTARZ, C. F.; FIGUEROA, S. N.; BONATTI, J. P.; SOUZA, D. C. de. Configuration and hindcast quality assessment of a brazilian global sub-seasonal prediction system. **Quarterly Journal of the Royal Meteorological Society**, Wiley Online Library, v. 146, n. 728, p. 1067–1084, 2020.

HALTINER, G. J.; WILLIAMS, R. T. **Numerical prediction and dynamic meteorology**. [S.l.], 1980.

HARRIS, I.; OSBORN, T. J.; JONES, P.; LISTER, D. Version 4 of the cru ts monthly high-resolution gridded multivariate climate dataset. **Scientific data**, Nature Publishing Group UK London, v. 7, n. 1, p. 109, 2020.

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2007.

HEBB, D. O. **The organization of behavior: a neuropsychological theory**. [S.l.]: Science editions, 1949.

HENDON, H. H.; LIEBMANN, B.; NEWMAN, M.; GLICK, J. D.; SCHEMM, J. Medium-range forecast errors associated with active episodes of themadden–julian oscillation. **Monthly Weather Review**, v. 128, n. 1, p. 69–86, 2000.

HENDON, H. H.; SALBY, M. L. The life cycle of the madden–julian oscillation. **Journal of Atmospheric Sciences**, v. 51, n. 15, p. 2225–2237, 1994.

JAMES, I. N. **Introduction to circulating atmospheres**. [S.l.]: Cambridge University Press, 1995.

JONES, C. Occurrence of extreme precipitation events in california and relationships with the madden–julian oscillation. **Journal of Climate**, American Meteorological Society, v. 13, n. 20, p. 3576–3587, 2000.

JUNIOR, F. d. C. V.; JONES, C.; GANDU, A. W.; MARTINS, E. S. P. Impacts of the madden–julian oscillation on the intensity and spatial extent of heavy precipitation events in northern northeast brazil. **International Journal of Climatology**, Wiley Online Library, v. 41, n. 6, p. 3628–3639, 2021.

KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. [S.l.]: Cambridge university press, 2003.

KAYANO, M.; KOUSKY, V. Intraseasonal (30–60 day) variability in the global tropics: principal modes and their evolution. **Tellus A**, Wiley Online Library, v. 51, n. 3, p. 373–386, 1999.

KENNEDY, J.; EBERHART, R. “particle swarm optimization,” proceedings of icnn’95–international conference on neural networks, perth, wa, australia. 1995.

- LAU, K.-M.; CHAN, P. Aspects of the 40–50 day oscillation during the northern summer as inferred from outgoing longwave radiation. **Monthly Weather Review**, v. 114, n. 7, p. 1354–1367, 1986.
- LI, J.; XIE, S.-P.; COOK, E. R.; HUANG, G.; D'ARRIGO, R.; LIU, F.; MA, J.; ZHENG, X.-T. Interdecadal modulation of el niño amplitude during the past millennium. **Nature climate change**, Nature Publishing Group UK London, v. 1, n. 2, p. 114–118, 2011.
- LICCIARDELLO, F.; ZEMA, D.; ZIMBONE, S.; BINGNER, R. Runoff and soil erosion evaluation by the annagnps model in a small mediterranean watershed. **Transactions of the ASABE**, American Society of Agricultural and Biological Engineers, v. 50, n. 5, p. 1585–1593, 2007.
- LIN, T.; GUO, T.; ABERER, K. Hybrid neural networks for learning the trend in time series. In: **Proceedings of the twenty-sixth international joint conference on artificial intelligence**. [S.l.: s.n.], 2017. p. 2273–2279.
- LOPES, J. E. G. **Manual do modelo SMAP**. 1999. <http://pha.poli.usp.br/LeArq.aspx?id_arq=3596>. Acesso em: 10 julho. 2023.
- LOPES, J. E. G.; BRAGA, B. P. F.; CONEJO, J. G. L. SMAP - A Simplified Hydrological Model. Water Resources Publications, Fort Collins, Colorado, USA, 1982.
- LORENZ, E. N. The dynamic response of the tropics to convective heating. **Journal of the Atmospheric Sciences**, American Meteorological Society, v. 24, n. 4, p. 466–479, 1967.
- MACEIRA, M.; DAMÁZIO, J.; GHIRARDI, A.; DANTAS, H. Periodic arma models applied to weekly streamflow forecasts. In: IEEE. **PowerTech Budapest 99. Abstract Records.(Cat. No. 99EX376)**. [S.l.], 1999. p. 86.
- MACIEL, S. A. *et al.* Análise da relação chuva-vazão na bacia hidrográfica do rio paranaíba, brasil. Universidade Federal de Uberlândia, 2017.
- MADDEN, R. A.; JULIAN, P. R. Detection of a 40–50 day oscillation in the zonal wind in the tropical pacific. **Journal of Atmospheric Sciences**, v. 28, n. 5, p. 702–708, 1971.
- MAGALHÃES, A. J.; ALVES, J. M. B.; SILVA, E. M. d.; NUNES, F. T.; BARBOSA, A. C. B.; SANTOS, A. C. S. d.; SOMBRA, S. S. Veranicos no brasil: Observações e modelagens (cmip5). **Revista Brasileira de Meteorologia**, SciELO Brasil, v. 34, p. 597–626, 2020.
- MAIER, H. R.; DANDY, G. C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environmental modelling & software**, Elsevier, v. 15, n. 1, p. 101–124, 2000.
- MALLAT, S. **A wavelet tour of signal processing**. [S.l.]: Elsevier, 1999.
- MARENGO, J. A.; ALVES, L. M.; BESERRA, E. A.; LACERDA, F. F. Variabilidade e mudanças climáticas no semiárido brasileiro. **Recursos hídricos em regiões áridas e semiáridas**, Instituto Nacional do Semiárido Campina Grande, v. 1, p. 385–422, 2011.
- MARENGO, J. A. *et al.* Vulnerabilidade, impactos e adaptação à mudança do clima no semi-árido do brasil. **Parcerias estratégicas**, v. 27, p. 149–175, 2008.

- MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in northeast brazil—past, present, and future. **Theoretical and Applied Climatology**, Springer, v. 129, p. 1189–1200, 2017.
- MARTINS, E. S. P. R.; MAGALHÃES, A. R.; FONTENELE, D. A seca plurianual de 2010-2017 no nordeste e seus impactos. *Parcerias Estratégicas*, 2017.
- MATTHEWS, A. J. Intraseasonal variability over tropical africa during northern summer. **Journal of Climate**, v. 17, n. 12, p. 2427–2440, 2004.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.
- MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. [S.l.]: Oficina de textos, 2017.
- MINSKY, M.; PAPERT, S. *Perceptrons*. MIT press, 1969.
- MO, K. C.; HIGGINS, R. Tropical convection and precipitation regimes in the western united states. **Journal of Climate**, v. 11, n. 9, p. 2404–2423, 1998.
- MOLION, L. C. B.; BERNARDO, S. d. O. Uma revisão da dinâmica das chuvas no nordeste brasileiro. **Revista Brasileira de Meteorologia**, Rio de Janeiro e RJ RJ, v. 17, n. 1, p. 1–10, 2002.
- MONTEIRO¹, J. B. A influência de teleconexões e sistemas meteorológicos produtores de precipitação no semiárido nordestino. **Revista Brasileira de Geografia Física**, v. 15, n. 01, p. 312–332, 2022.
- MORETTIN, P. A. **Ondas e Ondaletas Vol. 23**. [S.l.]: Edusp, 1999.
- MOURA, A. D.; STUDZINSKI, C. Previsão climática e centros de aplicação. In: **CONGRESSO BRASILEIRO DE METEOROLOGIA**. [S.l.: s.n.], 1994. v. 8, p. 869.
- NASCIMENTO, F.; DIAS, A.; FILHO, A. F.; ARCE, J.; MIRANDA, G. Uso da meta-heurística otimização por exame de partículas no planejamento florestal. **Scientia Forestalis**, v. 40, n. 96, p. 557–565, 2012.
- NAYAK, P. C.; SUDHEER, K.; RANGAN, D.; RAMASASTRI, K. A neuro-fuzzy computing technique for modeling hydrological time series. **Journal of Hydrology**, Elsevier, v. 291, n. 1-2, p. 52–66, 2004.
- NIELSEN, A. **Practical time series analysis: Prediction with statistics and machine learning**. [S.l.]: O'Reilly Media, 2019.
- NIGAM, S.; PYLE, J.; CURRY, J. **Teleconnections. Encyclopedia of atmospheric sciences**. [S.l.]: Academic Press London, 2003.
- NOTTER, B.; MACMILLAN, L.; VIVIROLI, D.; WEINGARTNER, R.; LINIGER, H.-P. Impacts of environmental change on water resources in the mt. kenya region. **Journal of Hydrology**, Elsevier, v. 343, n. 3-4, p. 266–278, 2007.
- NOURANI, V.; ALAMI, M. T.; AMINFAR, M. H. A combined neural-wavelet model for prediction of ligvanchai watershed precipitation. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 22, n. 3, p. 466–472, 2009.

OLAH, C. Understanding Istm networks. 2015.

OLIVEIRA, C. P. de; AMBRIZZI, T.; AIMOLA, L. Influence of intraseasonal variability on precipitation in northern south america during the winter season. **International Journal of Climatology**, Wiley Online Library, v. 37, n. 4, p. 2177–2186, 2017.

OLIVEIRA, H. M. de. Análise de sinais para engenheiros: Uma abordagem via wavelets. **Rio de Janeiro: Brasport**, 2007.

ONS, O. N. do S. E. **Relatório Anual de Avaliação das Previsões de Vazões – 2015**. [S.l.], 2015.

PAEGLE, J. N.; BYERLE, L. A.; MO, K. C. Intraseasonal modulation of south american summer precipitation. **Monthly Weather Review**, American Meteorological Society, v. 128, n. 3, p. 837–850, 2000.

PAIVA, L. F. G.; ACIOLI, G. C. L. Previsão de vazões com o modelo cpins – cálculo e previsão de vazões naturais e incrementais a sobradinho. In: **Anais do I Workshop de previsão de vazões**. Rio de Janeiro: ONS, 2007.

PARASURAMAN, K.; ELSHORBAGY, A. Cluster-based hydrologic prediction using genetic algorithm-trained neural networks. **Journal of Hydrologic Engineering**, American Society of Civil Engineers, v. 12, n. 1, p. 52–62, 2007.

PEIXOTO, J. P.; OORT, A. H.; LORENZ, E. N. **Physics of climate**. [S.l.]: Springer, 1992. v. 520.

PHILANDER, S. G. 9. el niño, la niña, and the southern oscillation. In: **Is the Temperature Rising?** [S.l.]: Princeton University Press, 2018. p. 143–158.

POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization: An overview. **Swarm intelligence**, Springer, v. 1, p. 33–57, 2007.

RATHINASAMY, M.; AGARWAL, A.; SIVAKUMAR, B.; MARWAN, N.; KURTHS, J. Wavelet analysis of precipitation extremes over india and teleconnections to climate indices. **Stochastic Environmental Research and Risk Assessment**, Springer, v. 33, p. 2053–2069, 2019.

REIS, A. J. R.; SILVA, A. P. Aplicação da transformada wavelet discreta na previsão de carga a curto prazo via redes neurais. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, SciELO Brasil, v. 15, n. 1, p. 101–108, 2004.

RIBEIRO, D. d. C. M. Modelo de previsão de vazão aplicado ao nordeste brasileiro utilizando a informação climática para auxiliar a operação de hidrossistemas. 2011.

RIBEIRO, S. C. Caracterização geoambiental da sub-bacia do rio salgado na mesorregião sul cearense–parte i–clima e arcabouço geológico. **Geoconexões**, v. 1, p. 4–16, 2017.

ROCHA, S. de S.; ALMEIDA, J. R. F. de. A variabilidade da precipitação nas sub-bacias do alto e do médio jaguaribe e seu efeito sob os açudes castanhão e orós, localizados no estado do ceará. **Revista Brasileira de Geografia Física**, v. 14, n. 1, p. 025–036.

RODRIGUES, I. B. Análise dos veranicos e vulnerabilidade à produção de milho e feijão nos inhamuns-ce. 2016.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986.

SAHA, S.; MOORTHY, S.; WU, X.; WANG, J.; NADIGA, S.; TRIPP, P.; BEHRINGER, D.; HOU, Y.-T.; CHUANG, H.-y.; IREDELL, M. *et al.* The ncep climate forecast system version 2. **Journal of climate**, American Meteorological Society, v. 27, n. 6, p. 2185–2208, 2014.

SAHOO, S.; JHA, M. K. Pattern recognition in lithology classification: modeling using neural networks, self-organizing maps and genetic algorithms. **Hydrogeology Journal**, Springer Nature BV, v. 25, n. 2, p. 311, 2017.

SALAME, C. W.; QUEIROZ, J. C. B.; SOUZA, E. B. de; FARIAS, V. J. da C.; ROCHA, E. J. P. da; MOURA, H. P. Um estudo comparativo dos modelos box-jenkins e redes neurais artificiais na previsão de vazões e precipitações pluviométricas da bacia araguaia, tocantins, brasil. **Brazilian Journal of Environmental Sciences (Online)**, n. 52, p. 28–43, 2019.

SAMPAIO, G.; DIAS, P. L. da S. Evolução dos modelos climáticos e de previsão de tempo e clima. **Revista USP**, n. 103, p. 41–54, 2014.

SANTANA, A. S. d.; SANTOS, G. R. d. Impactos da seca de 2012-2017 na região semiárida do nordeste: notas sobre a abordagem de dados quantitativos e conclusões qualitativas. Instituto de Pesquisa Econômica Aplicada (Ipea), 2020.

SANTOS, A. L. L. *et al.* Previsão de vazão afluente da uhe-tucuruí por redes neurais recorrentes lstm. 2022.

SCHARDONG, A.; SIMONOVIC, S. P.; GARCIA, J. I. B.; PORTO, R. L. L. comparação de algoritmos evolucionários na calibração de modelo chuva-vazão-smap. **XVIII Simpósio Brasileiro de Recursos Hídricos**, 2009.

SHIMIZU, M. H.; AMBRIZZI, T.; LIEBMANN, B. Extreme precipitation events and their relationship with enso and mjo phases over northern south america. **International Journal of Climatology**, Wiley Online Library, v. 37, n. 6, p. 2977–2989, 2017.

SILVA, B. C. d.; TUCCI, C. E. M.; COLLISCHONN, W. Previsão de vazão com modelos hidroclimáticos. **Rbrh: revista brasileira de recursos hídricos. Porto Alegre, RS: ABRH. Vol. 11, n. 3 (jul./set. 2006), p. 15-29**, 2006.

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas-curso prático. **São Paulo: Artliber**, 2010.

SILVEIRA, C. S. **Modelagem integrada de meteorologia e Recursos Hídricos em múltiplas escalas temporais e espaciais: aplicação no Ceará e no setor hidroelétrica brasileiro**. Tese (Doutorado) — Universidade Federal do Ceará, 2014.

SILVEIRA, S. M. B.; SILVA, M. d. G. Conflitos socioambientais por água no nordeste brasileiro: expropriações contemporâneas e lutas sociais no campo. **Revista katálysis**, SciELO Brasil, v. 22, p. 342–352, 2019.

- SOUSA, R. dos S.; SILVA, L.; GUEDES, E. B.; OLIVEIRA, M. B. L. de. Redes neurais artificiais aplicadas à previsão antecipada de precipitações na região central de manaus. **IV Escola Regional de Informática Norte I**, p. 1–9, 2017.
- SOUSA, W. d. S.; SOUSA, F. d. A. de. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio piacó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 14, n. 2, p. 173–180, 2010.
- SOUZA, E. B. D.; AMBRIZZI, T. Modulation of the intraseasonal rainfall over tropical brazil by the madden–julian oscillation. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, Wiley Online Library, v. 26, n. 13, p. 1759–1776, 2006.
- STACKELBERG, N. O. V.; CHESCHEIR, G.; SKAGGS, R.; AMATYA, D. Simulation of the hydrologic effects of afforestation in the tacuarembó river basin, uruguay. **Transactions of the ASABE**, American Society of Agricultural and Biological Engineers, v. 50, n. 2, p. 455–468, 2007.
- STRANG, G.; NGUYEN, T. **Wavelets and filter banks**. [S.l.]: SIAM, 1996.
- SUN, S.; BLECK, R.; BENJAMIN, S. G.; GREEN, B. W.; GRELL, G. A. Subseasonal forecasting with an icosahedral, vertically quasi-lagrangian coupled model. part i: Model overview and evaluation of systematic errors. **Monthly Weather Review**, American Meteorological Society, v. 146, n. 5, p. 1601–1617, 2018.
- TAN, X.; GAN, T. Y.; SHAO, D. Wavelet analysis of precipitation extremes over canadian ecoregions and teleconnections to large-scale climate anomalies. **Journal of Geophysical Research: Atmospheres**, Wiley Online Library, v. 121, n. 24, p. 14–469, 2016.
- TANGANG, F.; HSIEH, W.; TANG, B. Forecasting the equatorial pacific sea surface temperatures by neural network models. **Climate Dynamics**, Springer, v. 13, n. 2, p. 135–147, 1997.
- TODINI, E. Hydrological catchment modelling: past, present and future. **Hydrology and Earth System Sciences**, Copernicus GmbH, v. 11, n. 1, p. 468–482, 2007.
- TORRENCE, C.; COMPO, G. P. A practical guide to wavelet analysis. **Bulletin of the American Meteorological society**, American Meteorological Society, v. 79, n. 1, p. 61–78, 1998.
- TUNDISI, J. G. Novas perspectivas para a gestão de recursos hídricos. **Revista USP**, n. 70, p. 24–35, 2006.
- VALADÃO, C. E.; CARVALHO, L. M.; LUCIO, P. S.; CHAVES, R. R. Impacts of the madden–julian oscillation on intraseasonal precipitation over northeast brazil. **International Journal of Climatology**, Wiley Online Library, v. 37, n. 4, p. 1859–1884, 2017.
- VALADÃO, C. E.; LUCIO, P. S.; CHAVES, R. R.; CARVALHO, L. M. *et al.* Mjo modulation of station rainfall in the semiarid seridó, northeast brazil. **Atmospheric and Climate Sciences**, Scientific Research Publishing, v. 5, n. 04, p. 408, 2015.
- VIOLA, M. R.; MELLO, C. R. d.; JR, F. W. A.; SILVA, A. M. d. Modelagem hidrológica na bacia hidrográfica do rio aiuruoca, mg. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 13, p. 581–590, 2009.

VITART, F.; ROBERTSON, A. W. The sub-seasonal to seasonal prediction project (s2s) and the prediction of extreme events. **npj Climate and Atmospheric Science**, Nature Publishing Group, v. 1, n. 1, p. 1–7, 2018.

WANG, W.; DING, J. Wavelet network model and its application to the prediction of hydrology. **Nature and Science**, v. 1, n. 1, p. 67–71, 2003.

WHEELER, M. C.; HENDON, H. H. An all-season real-time multivariate mjo index: Development of an index for monitoring and prediction. **Monthly weather review**, v. 132, n. 8, p. 1917–1932, 2004.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. [S.l.], 1960.

WILKS, D. S. **Statistical methods in the atmospheric sciences**. [S.l.]: Academic press, 2011. v. 100.

WU, A.; HSIEH, W. W.; TANG, B. Neural network forecasts of the tropical pacific sea surface temperatures. **Neural networks**, Elsevier, v. 19, n. 2, p. 145–154, 2006.

YNOUE, R. Y.; REBOITA, M. S.; AMBRIZZI, T.; SILVA, G. A. da. **Meteorologia: noções básicas**. [S.l.]: Oficina de Textos, 2017.

YOUNG, C.-C.; LIU, W.-C.; CHUNG, C.-E. Genetic algorithm and fuzzy neural networks combined with the hydrological modeling system for forecasting watershed runoff discharge. **Neural Computing and Applications**, Springer, v. 26, p. 1631–1643, 2015.

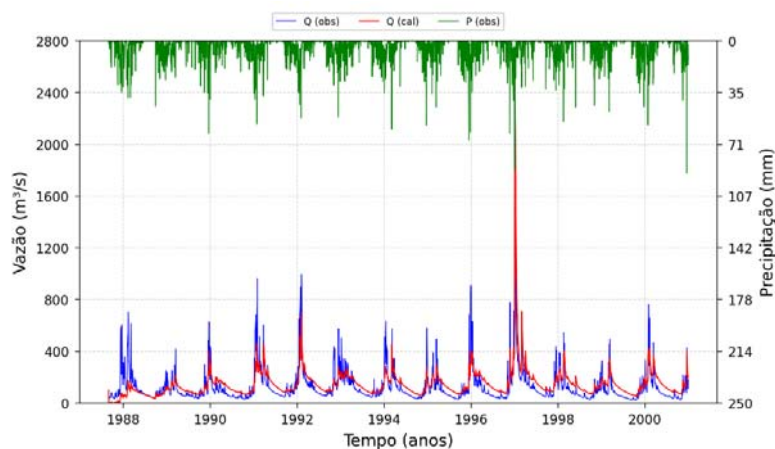
ZHANG, C. Madden-Julian oscillation. **Reviews of Geophysics**, Wiley Online Library, v. 43, n. 2, 2005.

ZHANG, Z.; PAN, X.; JIANG, T.; SUI, B.; LIU, C.; SUN, W. Monthly and quarterly sea surface temperature prediction based on gated recurrent unit neural network. **Journal of Marine Science and Engineering**, Multidisciplinary Digital Publishing Institute, v. 8, n. 4, p. 249, 2020.

ZHOU, X.; ZHU, Y.; HOU, D.; LUO, Y.; PENG, J.; WOBUS, R. Performance of the new ncep global ensemble forecast system in a parallel experiment. **Weather and Forecasting**, v. 32, n. 5, p. 1989–2004, 2017.


ANEXO A – CALIBRAÇÃO - SMAP

Figura 75 – Bacia do Retiro Baixo - Calibração SMAP.




Fonte: Próprio autor.

Figura 76 – Bacia de Três Marias - Calibração SMAP.




Fonte: Próprio autor.

Figura 77 – Bacia de Sobradinho - Calibração SMAP.




Fonte: Próprio autor.

Figura 78 – Bacia de Luiz Gonzaga - Calibração SMAP.




Fonte: Próprio autor.

Figura 79 – Bacia de Paulo Afonso - Calibração SMAP.



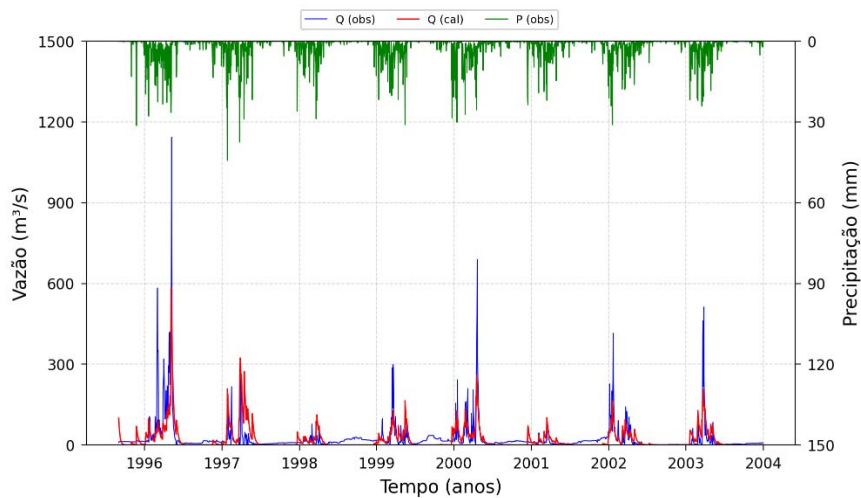
Fonte: Próprio autor.

Figura 80 – Bacia de Xingó - Calibração SMAP.




Fonte: Próprio autor.

Figura 81 – Bacia do Castanhão - Calibração SMAP.




Fonte: Próprio autor.

Figura 82 – Bacia do Orós - Calibração SMAP.



Fonte: Próprio autor.

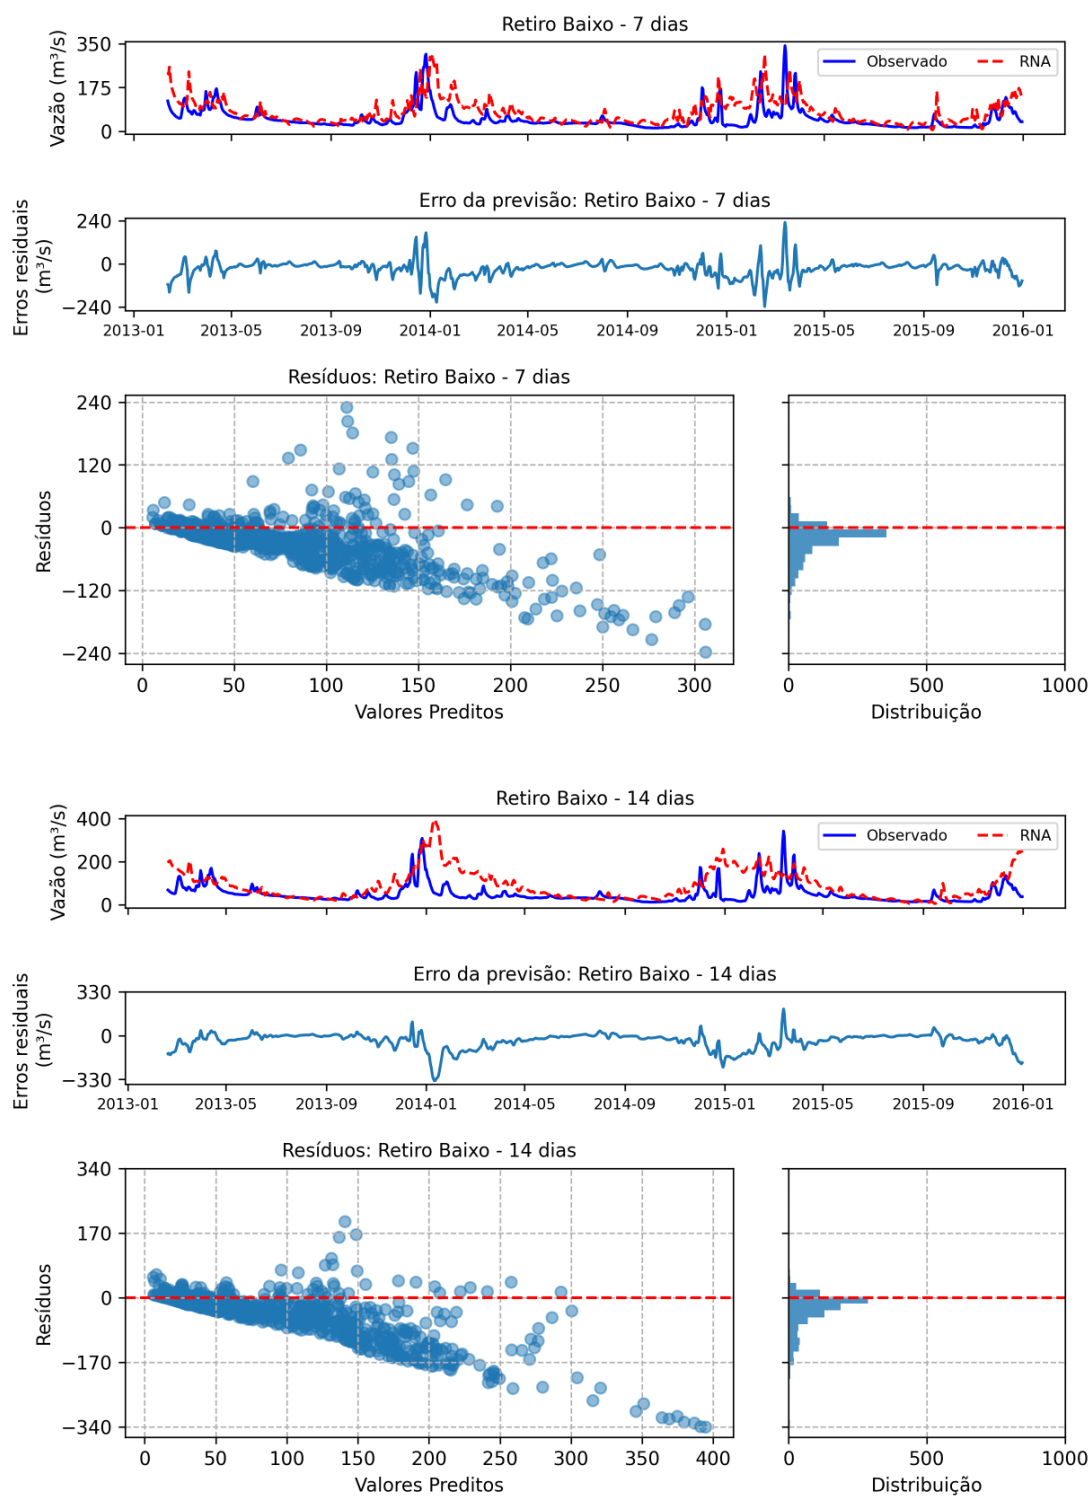
Figura 83 – Bacia do Banabuiú - Calibração SMAP.



Fonte: Próprio autor.

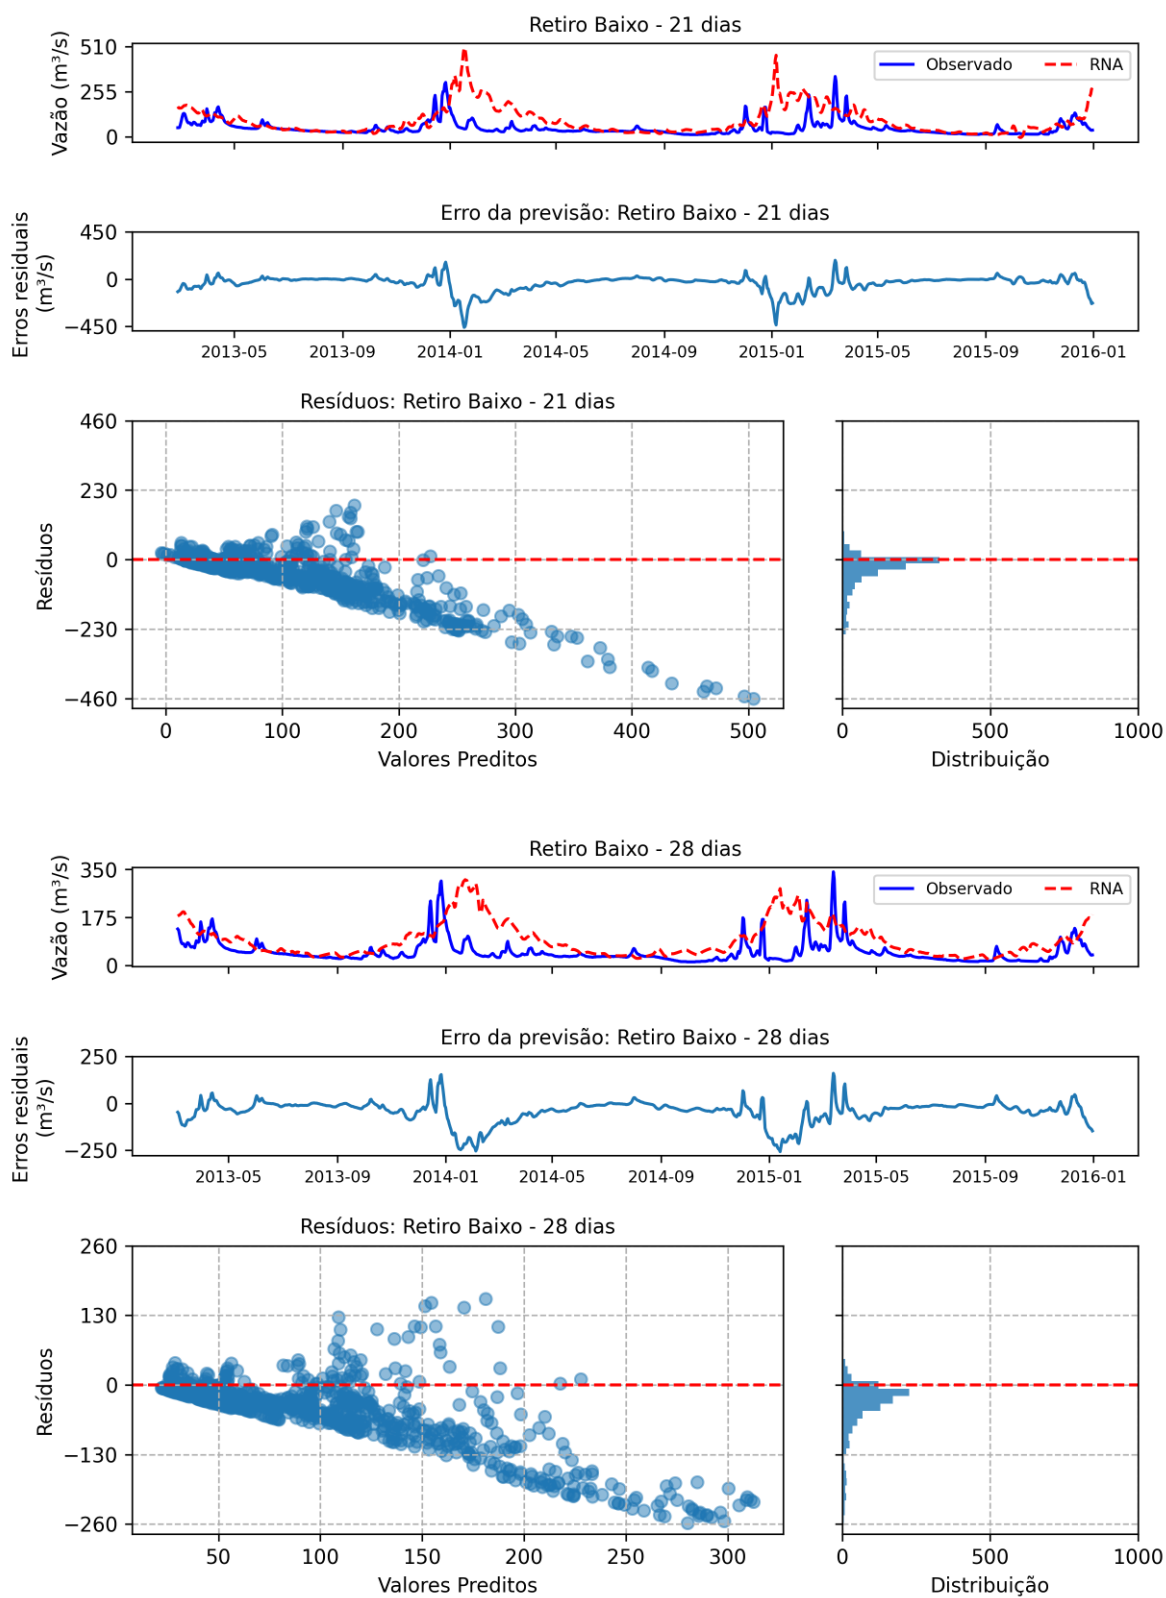
ANEXO B – REDES NEURAIS TRADICIONAIS

Figura 84 – Previsão RNA - Retiro Baixo 7 e 14 dias



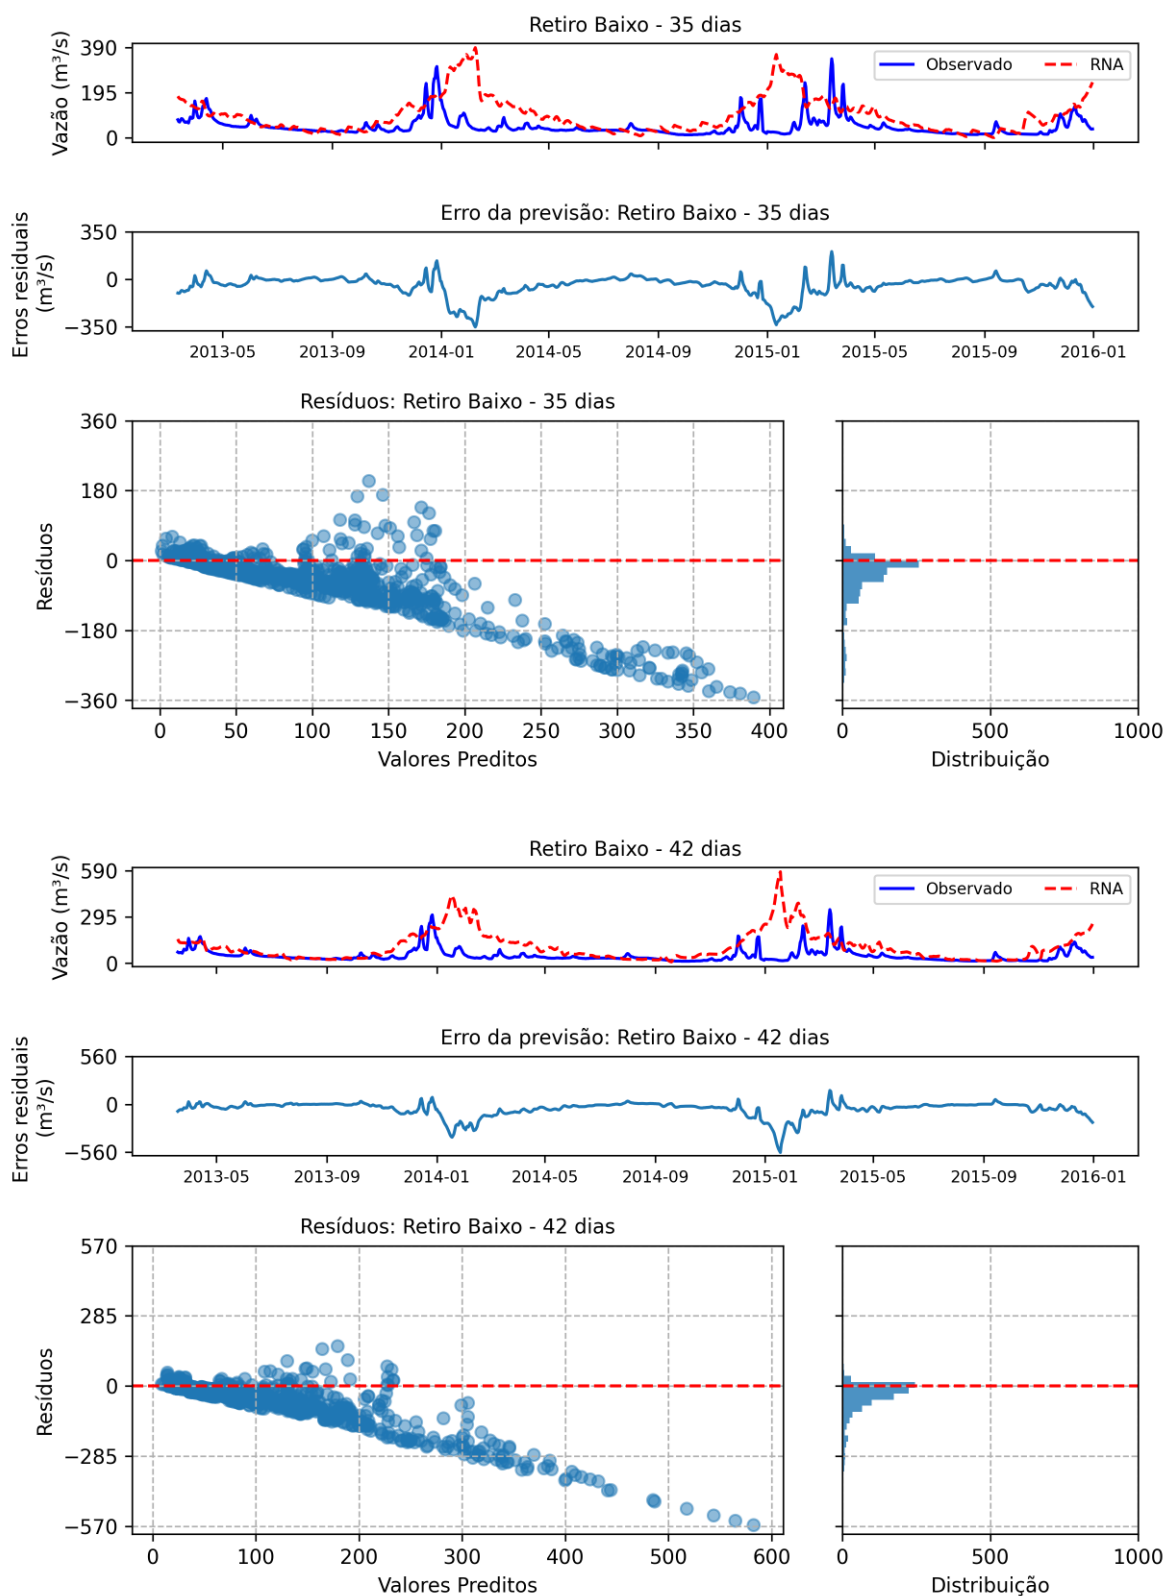
Fonte: Próprio autor

Figura 85 – Previsão RNA - Retiro Baixo 21 e 28 dias



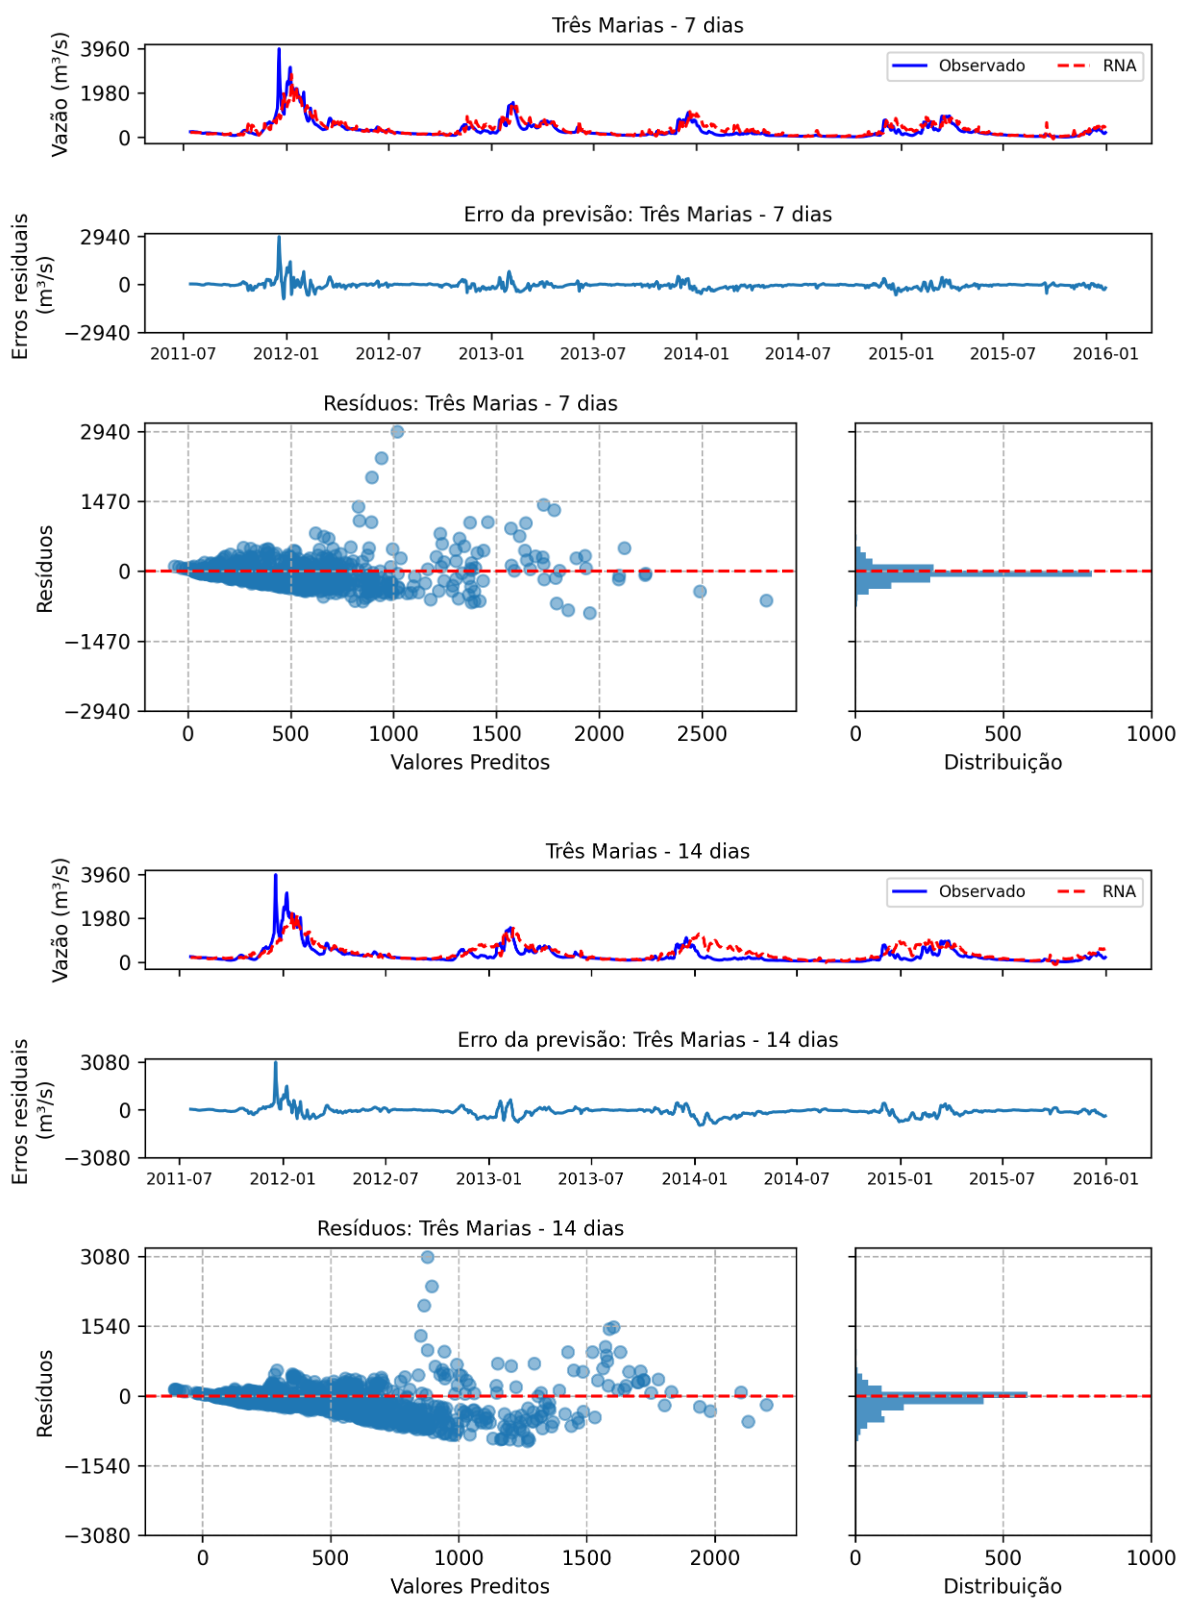
Fonte: Próprio autor

Figura 86 – Previsão RNA - Retiro Baixo 35 e 42 dias



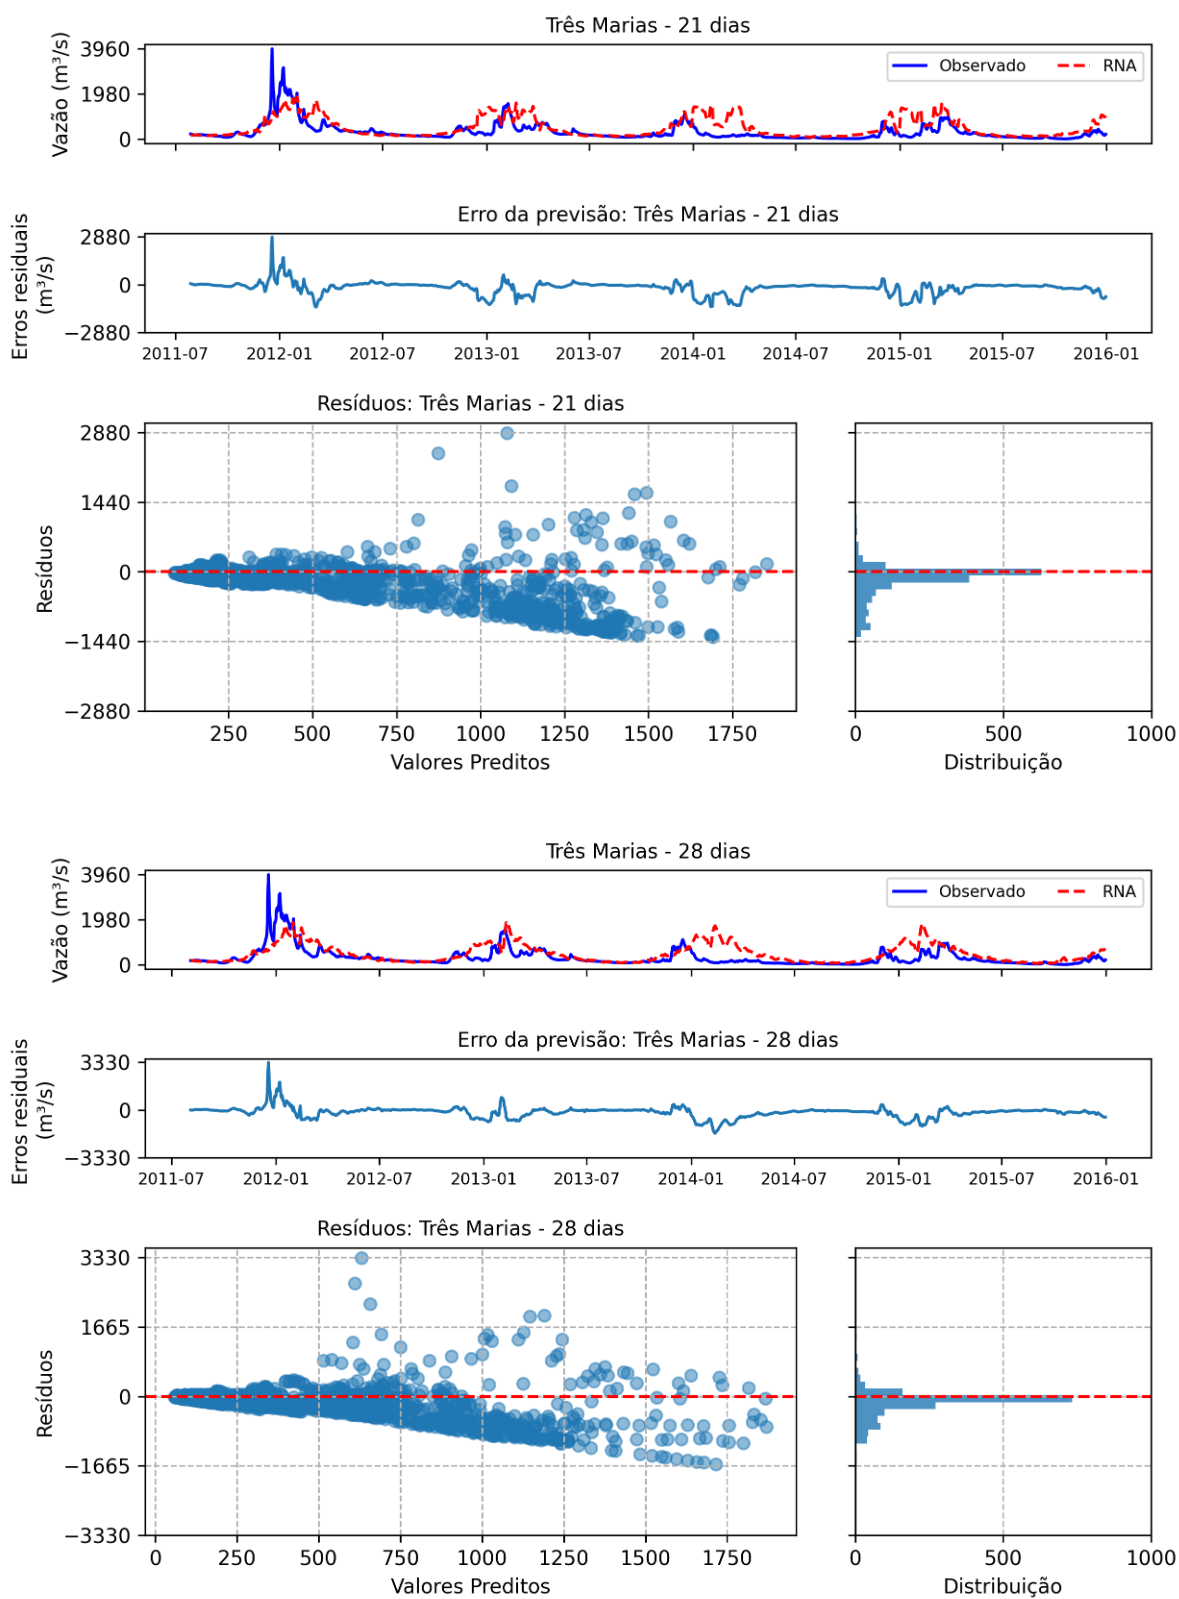
Fonte: Próprio autor

Figura 87 – Previsão RNA - Três Marias 7 e 14 dias



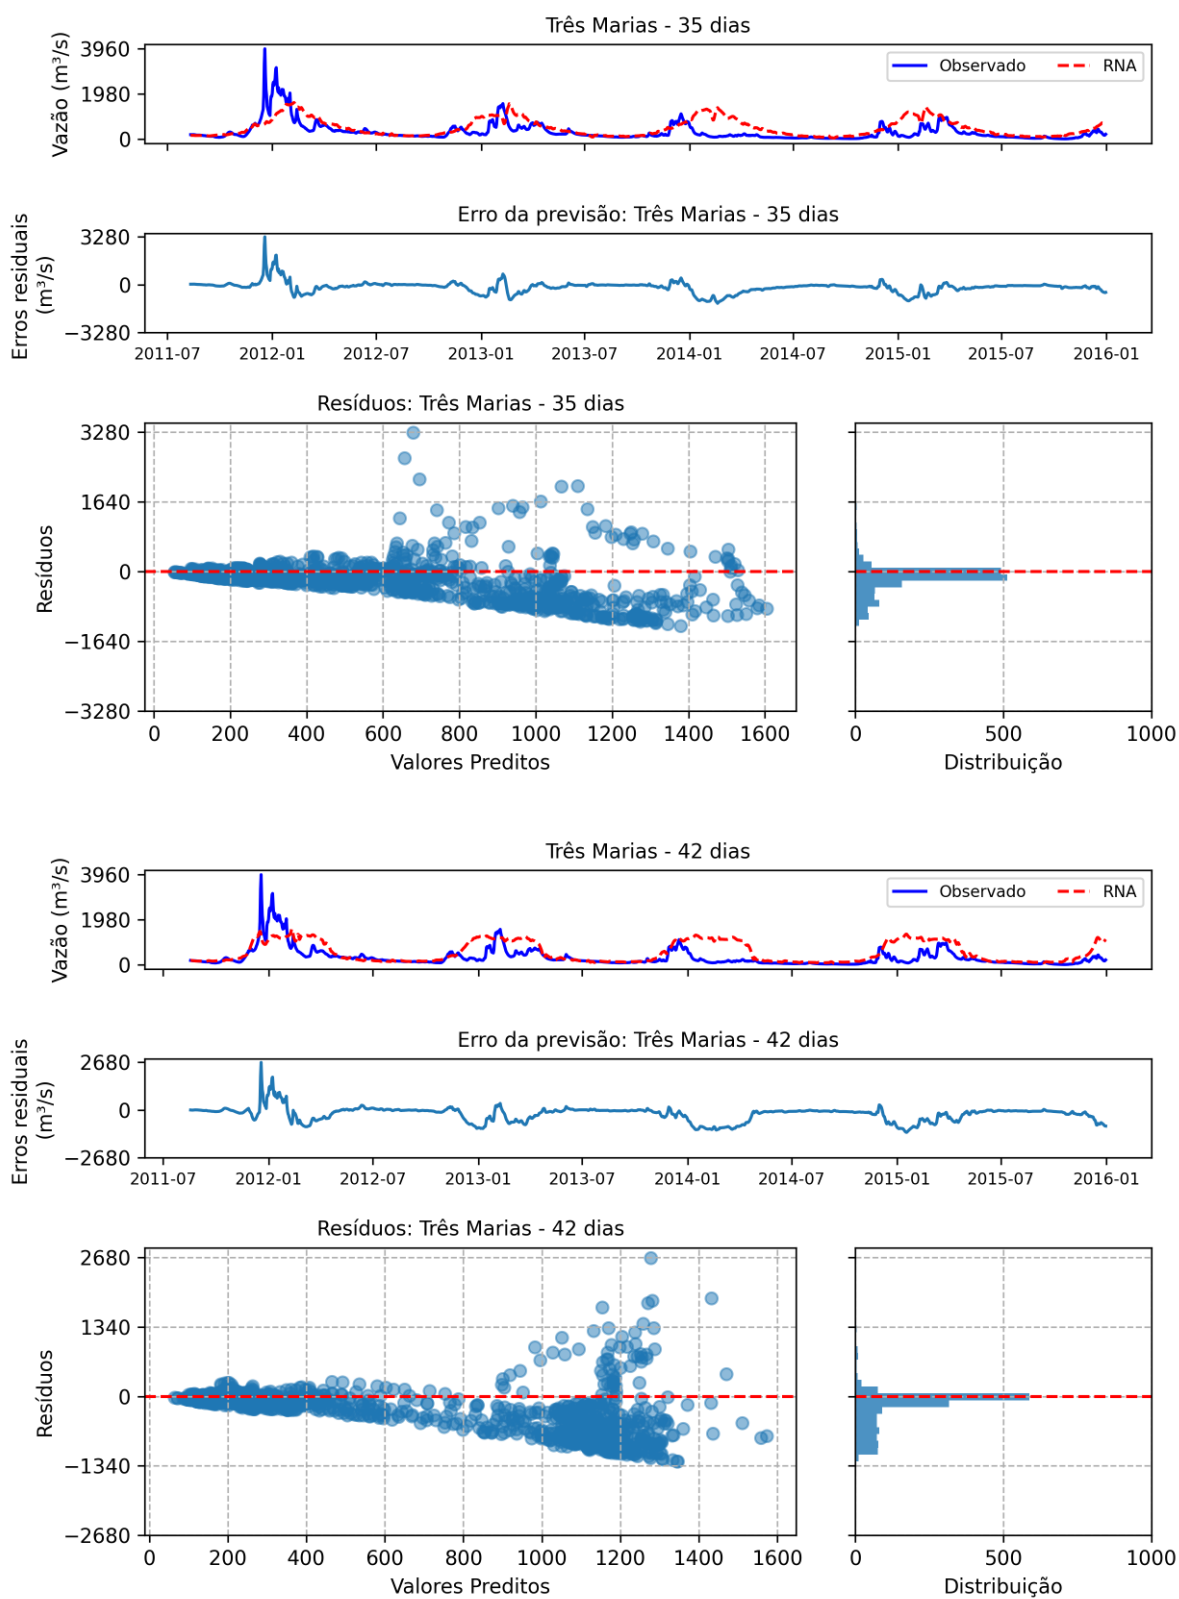
Fonte: Próprio autor

Figura 88 – Previsão RNA - Três Marias 21 e 28 dias



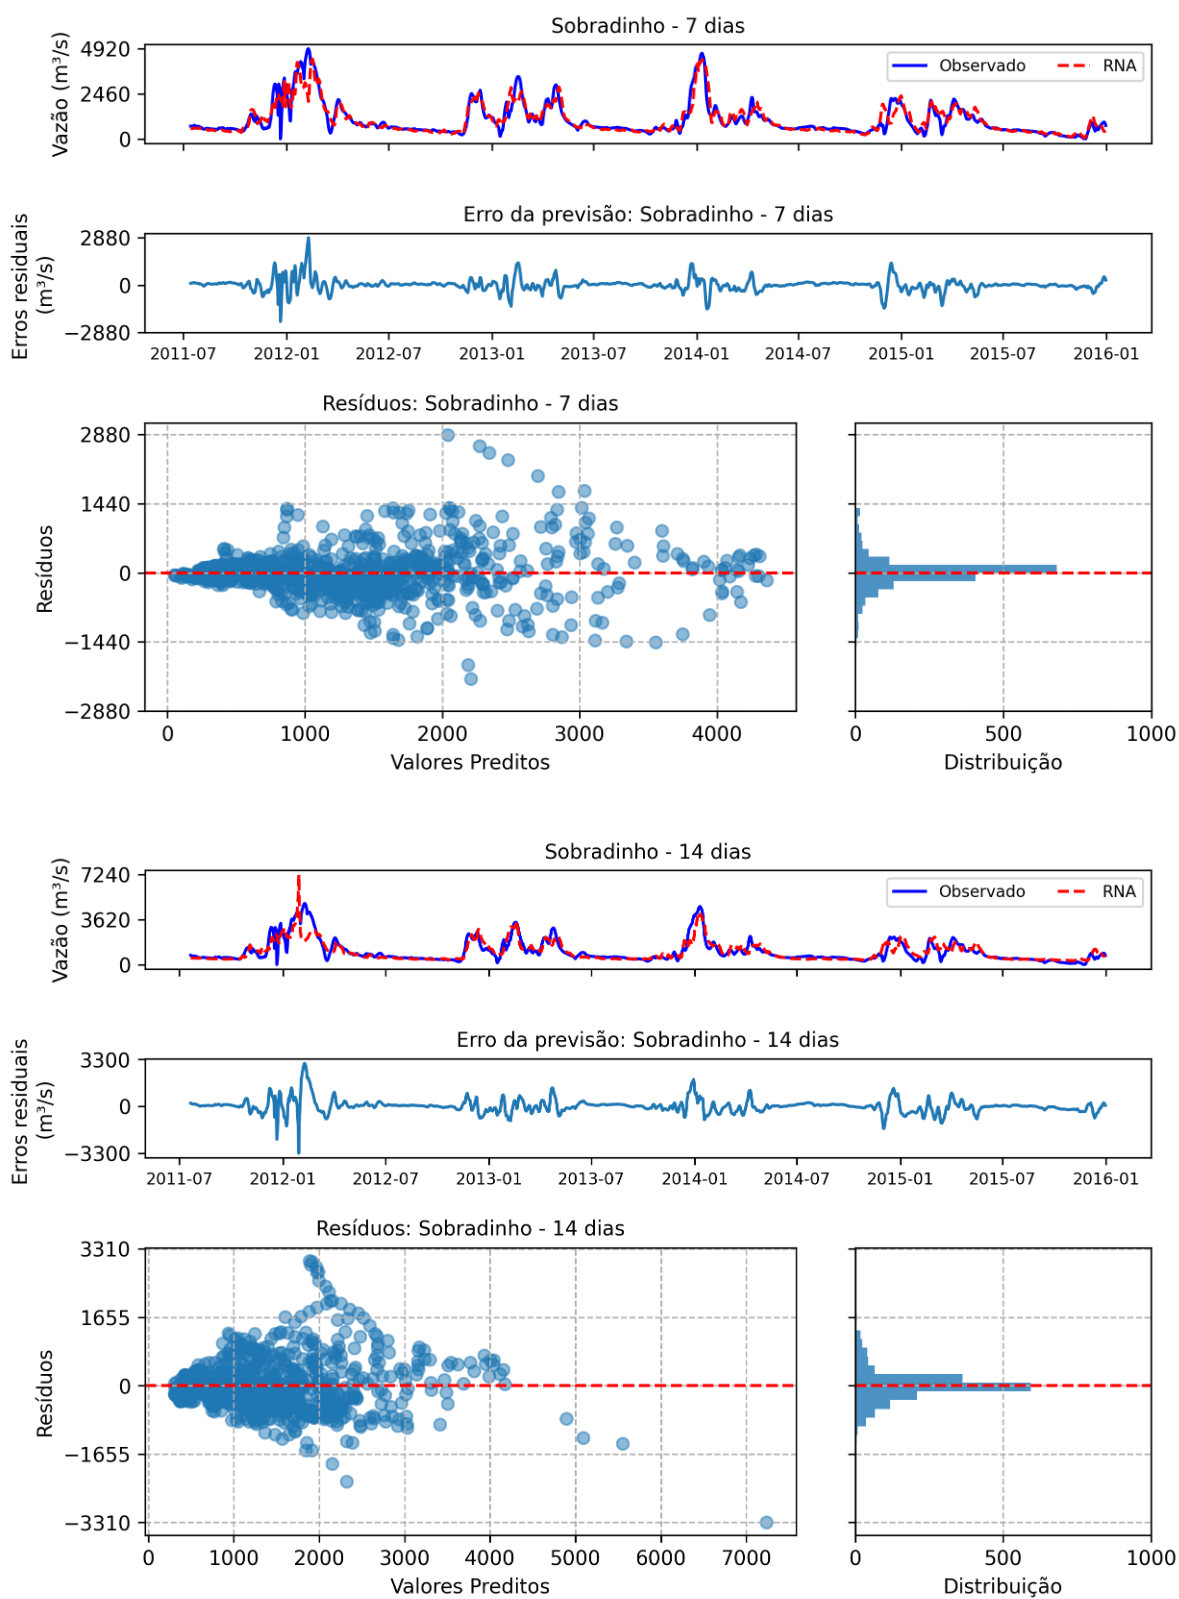
Fonte: Próprio autor

Figura 89 – Previsão RNA - Três Marias 35 e 42 dias



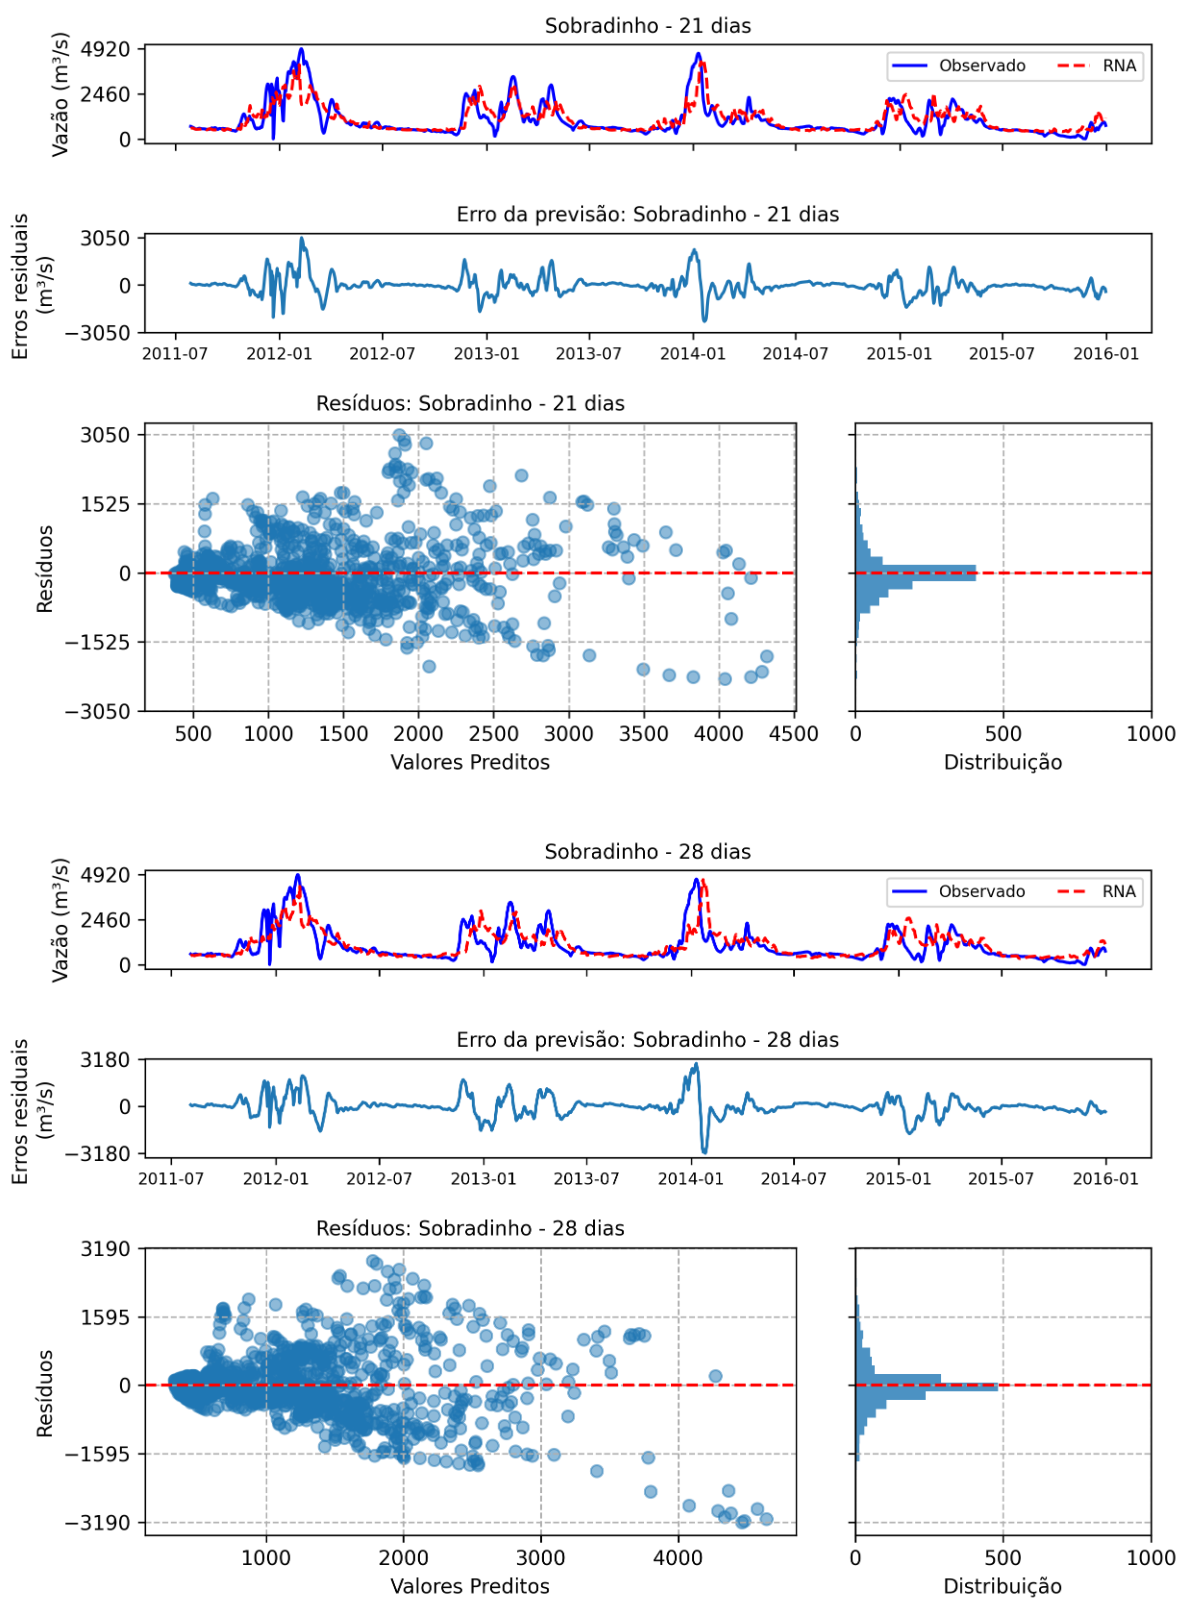
Fonte: Próprio autor

Figura 90 – Previsão RNA - Sobradinho 7 e 14 dias



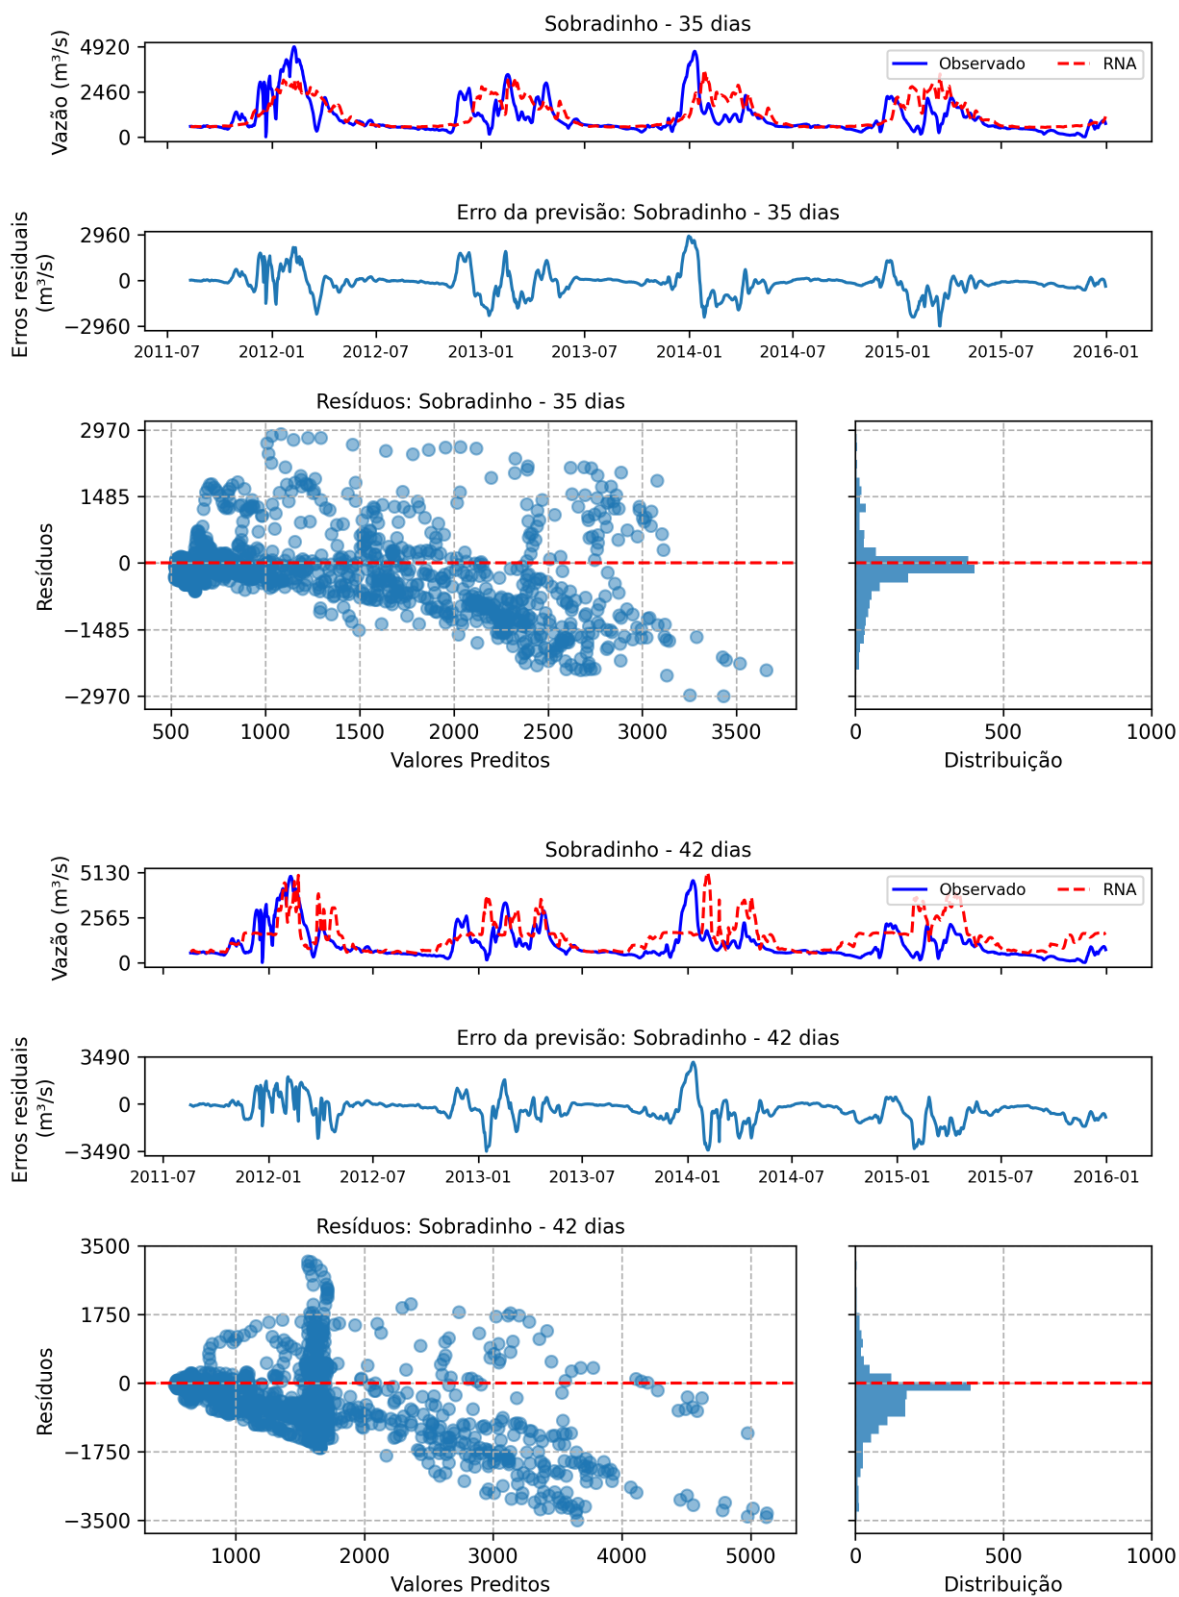
Fonte: Próprio autor

Figura 91 – Previsão RNA - Sobradinho 21 e 28 dias



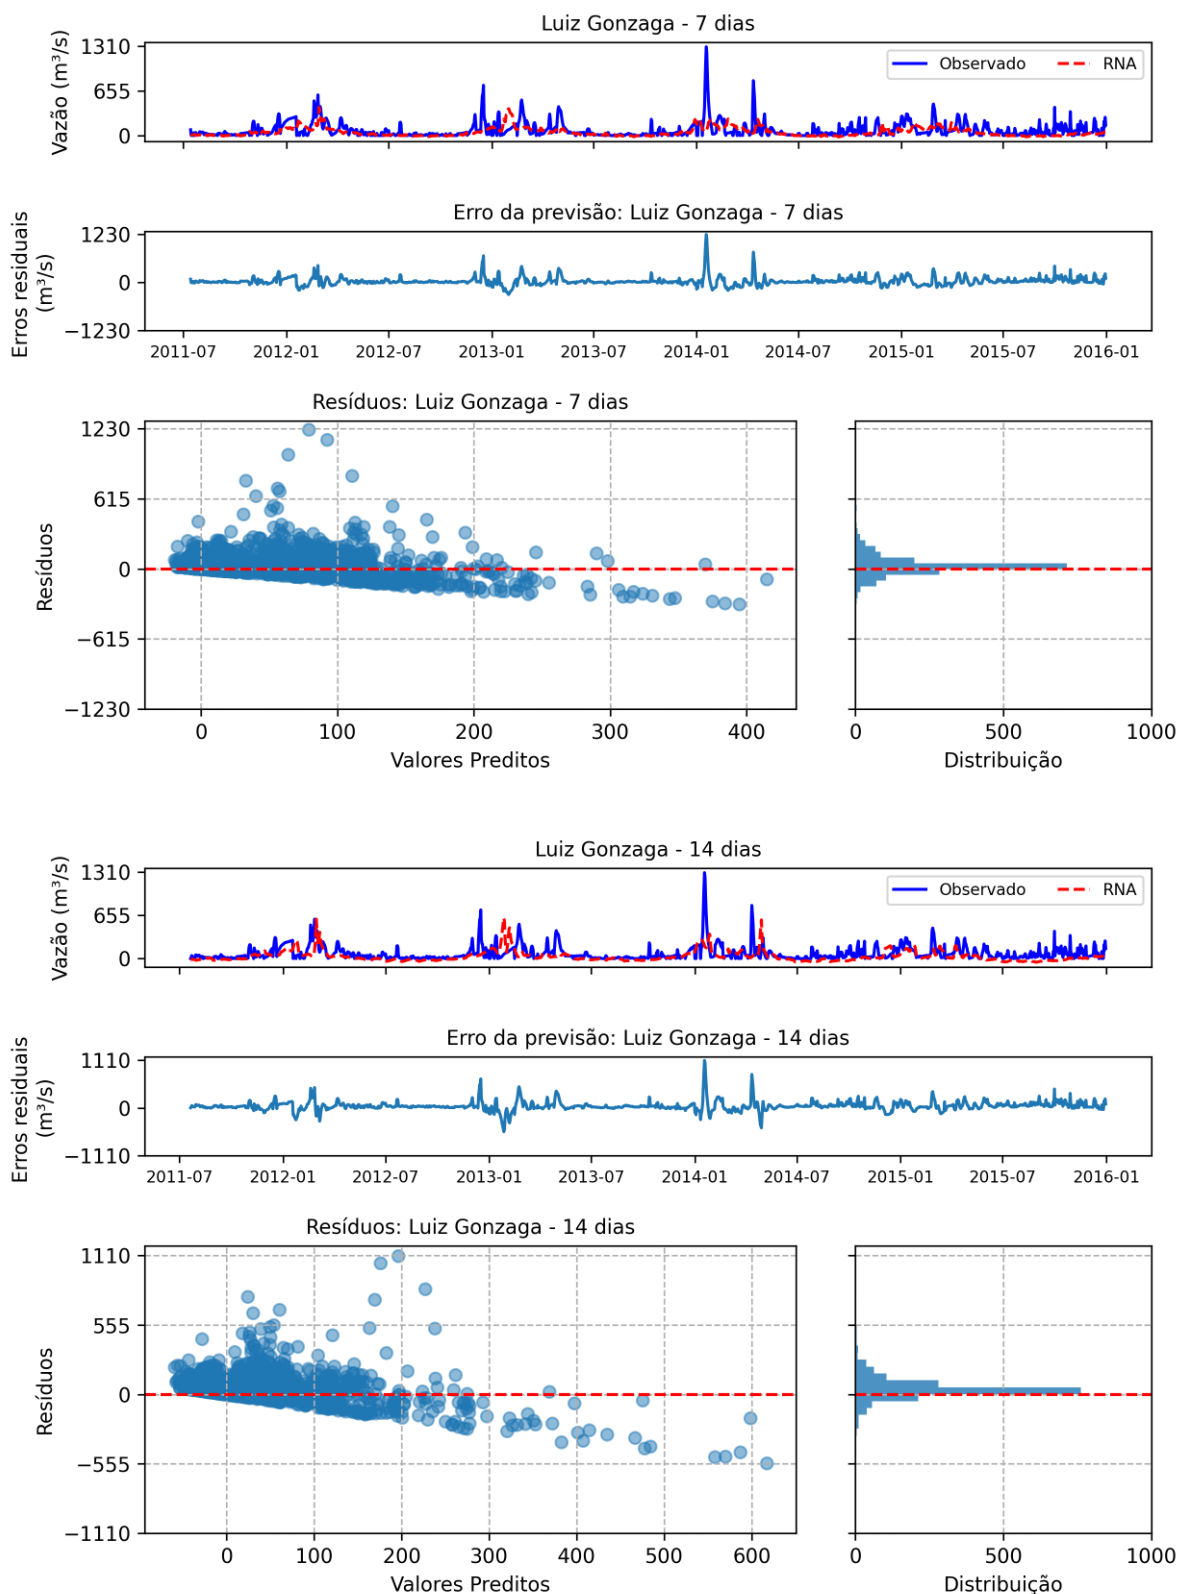
Fonte: Próprio autor

Figura 92 – Previsão RNA - Sobradinho 35 e 42 dias



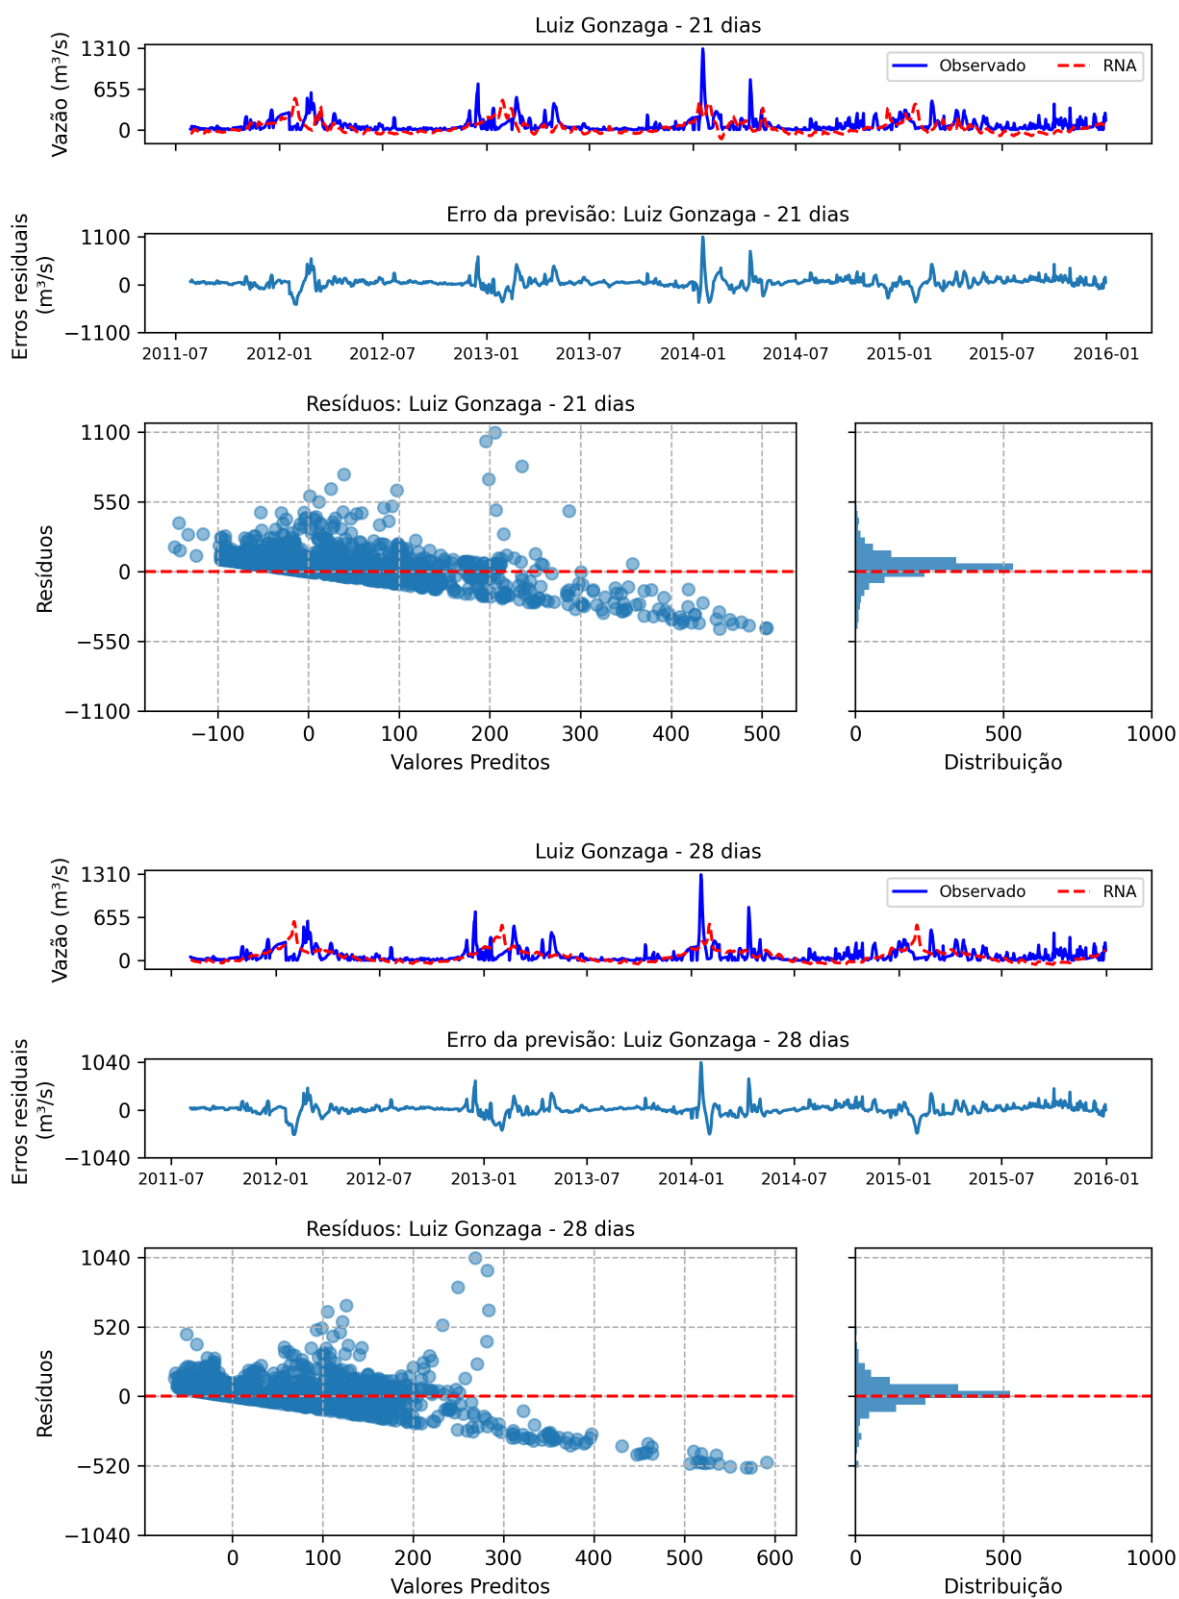
Fonte: Próprio autor

Figura 93 – Previsão RNA - Luiz Gonzaga 7 e 14 dias



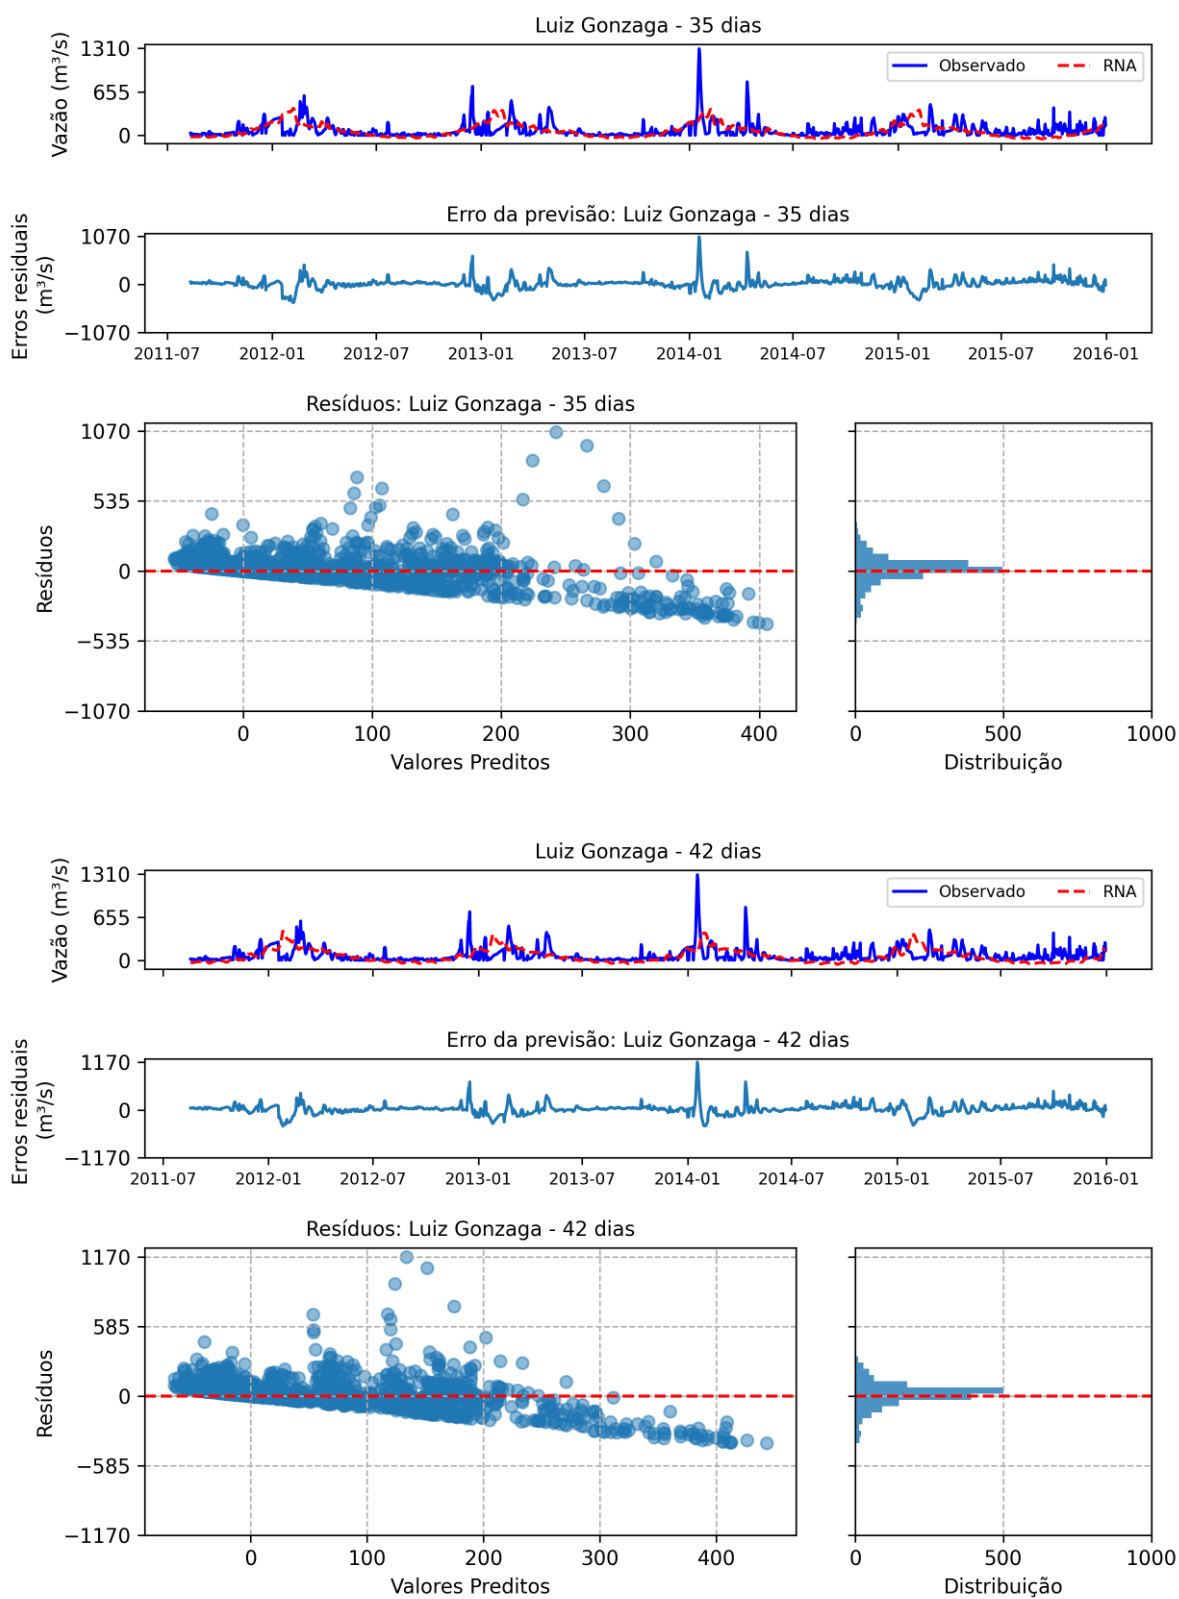
Fonte: Próprio autor

Figura 94 – Previsão RNA - Luiz Gonzaga 21 e 28 dias



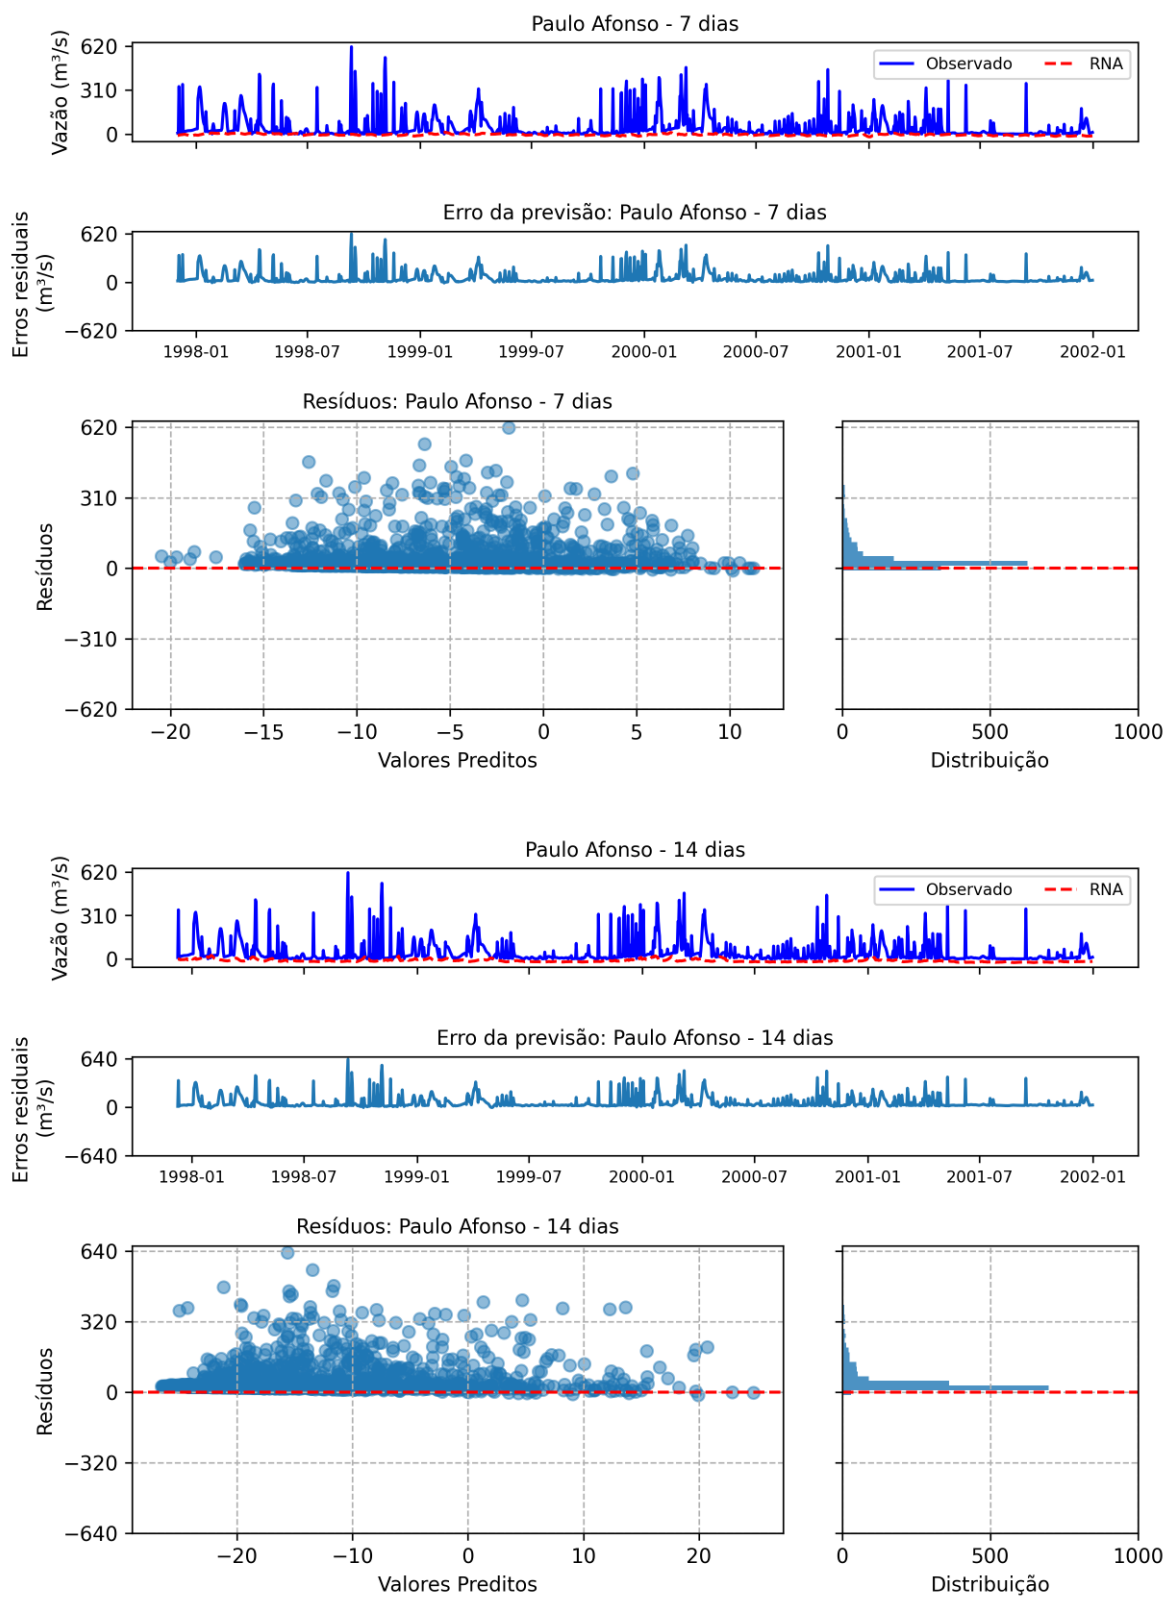
Fonte: Próprio autor

Figura 95 – Previsão RNA - Luiz Gonzaga 35 e 42 dias



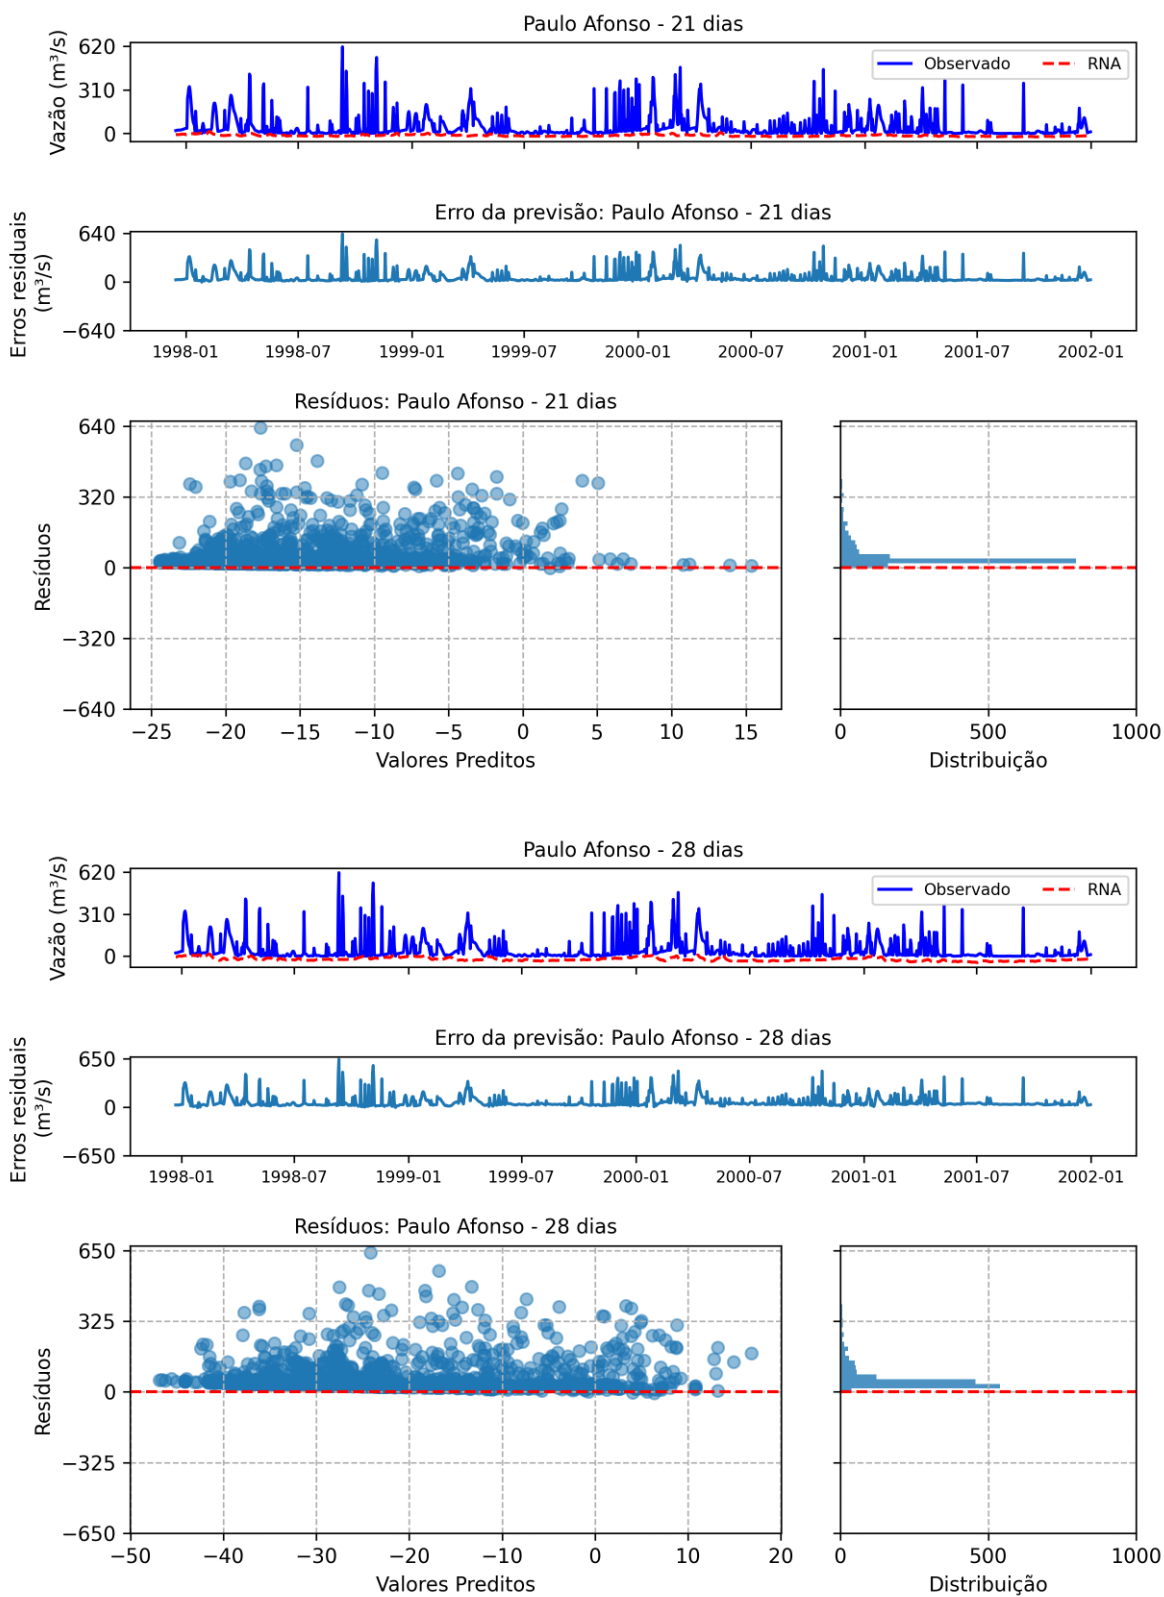
Fonte: Próprio autor

Figura 96 – Previsão RNA - Paulo Afonso 7 e 14 dias



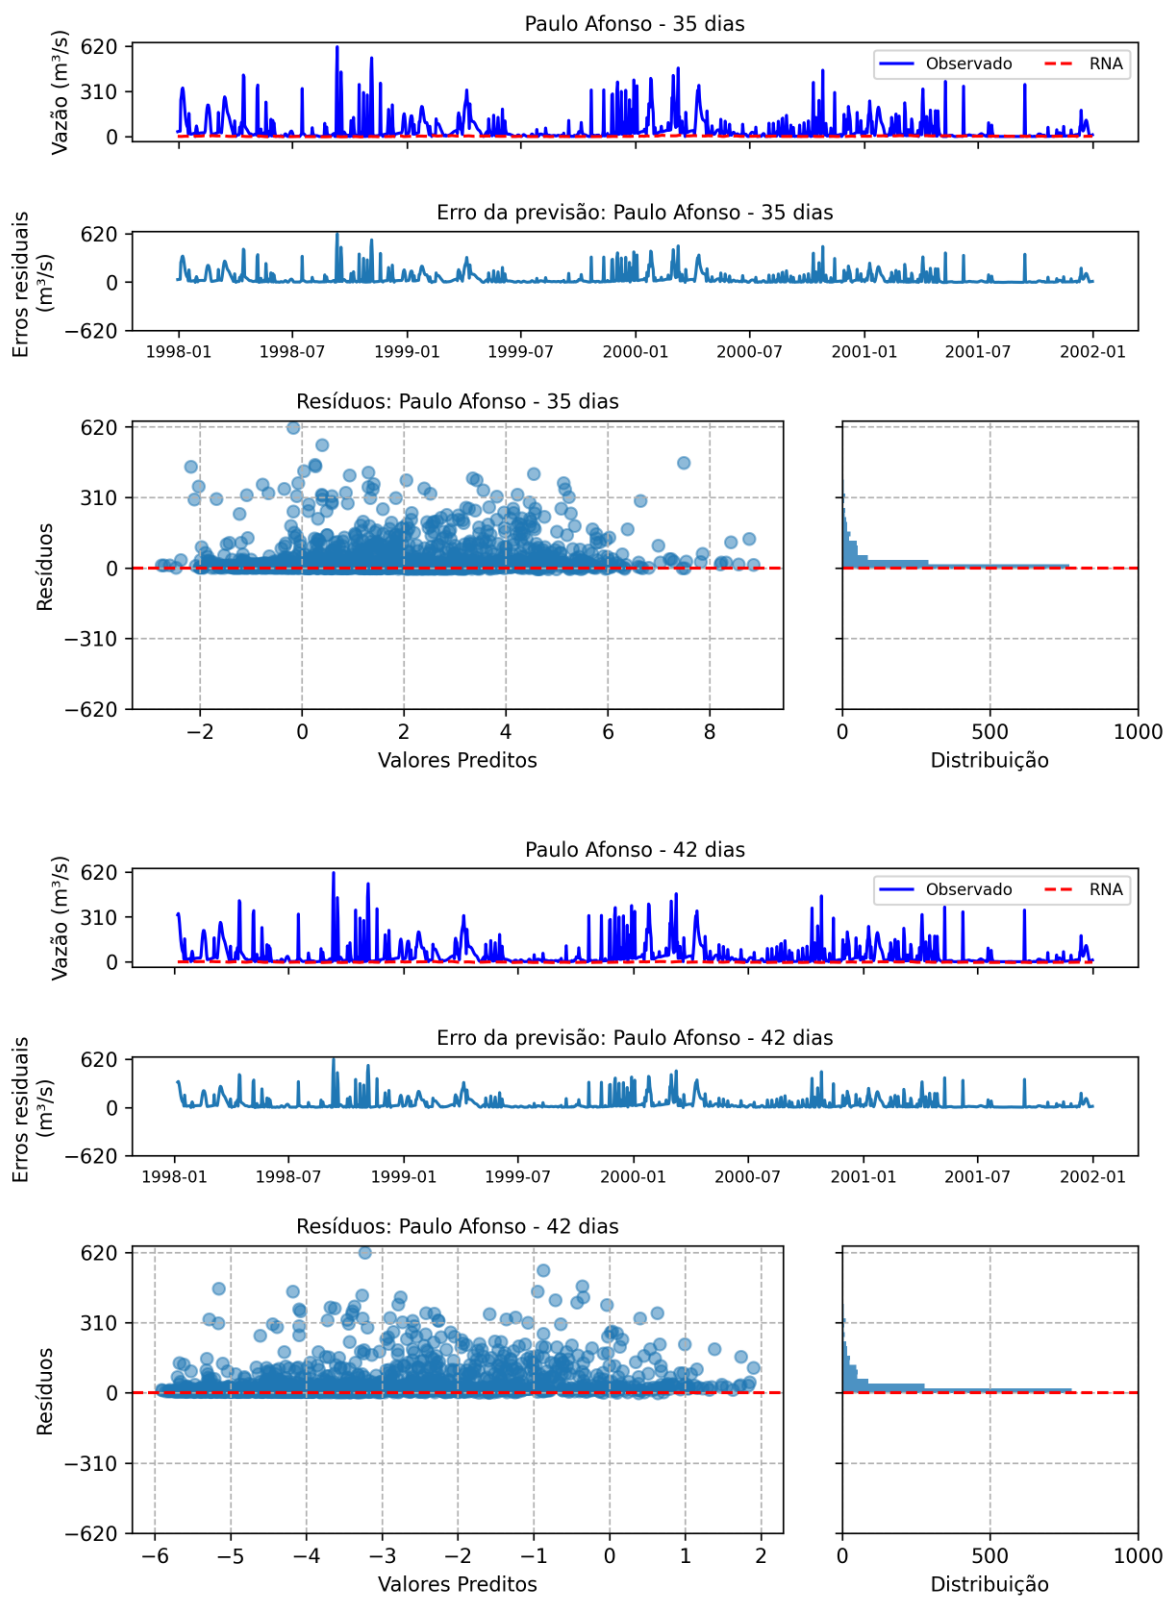
Fonte: Próprio autor

Figura 97 – Previsão RNA - Paulo Afonso 21 e 28 dias



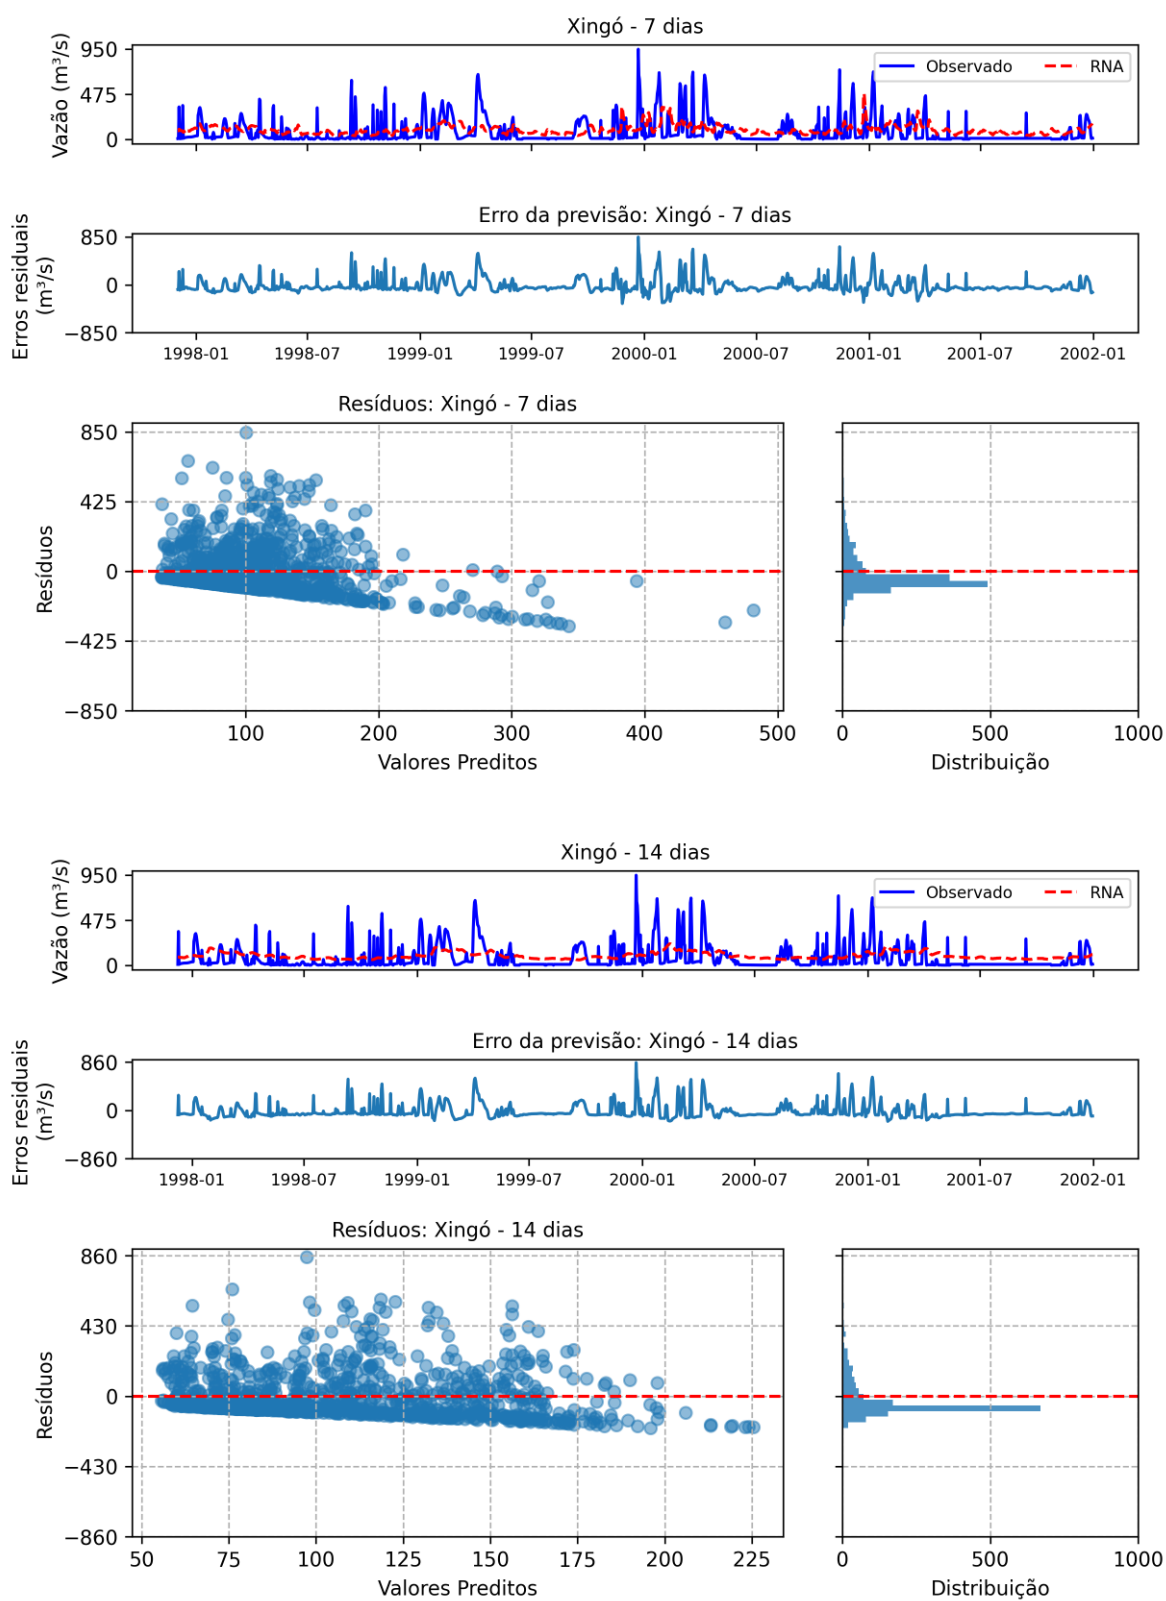
Fonte: Próprio autor

Figura 98 – Previsão RNA - Paulo Afonso 35 e 42 dias



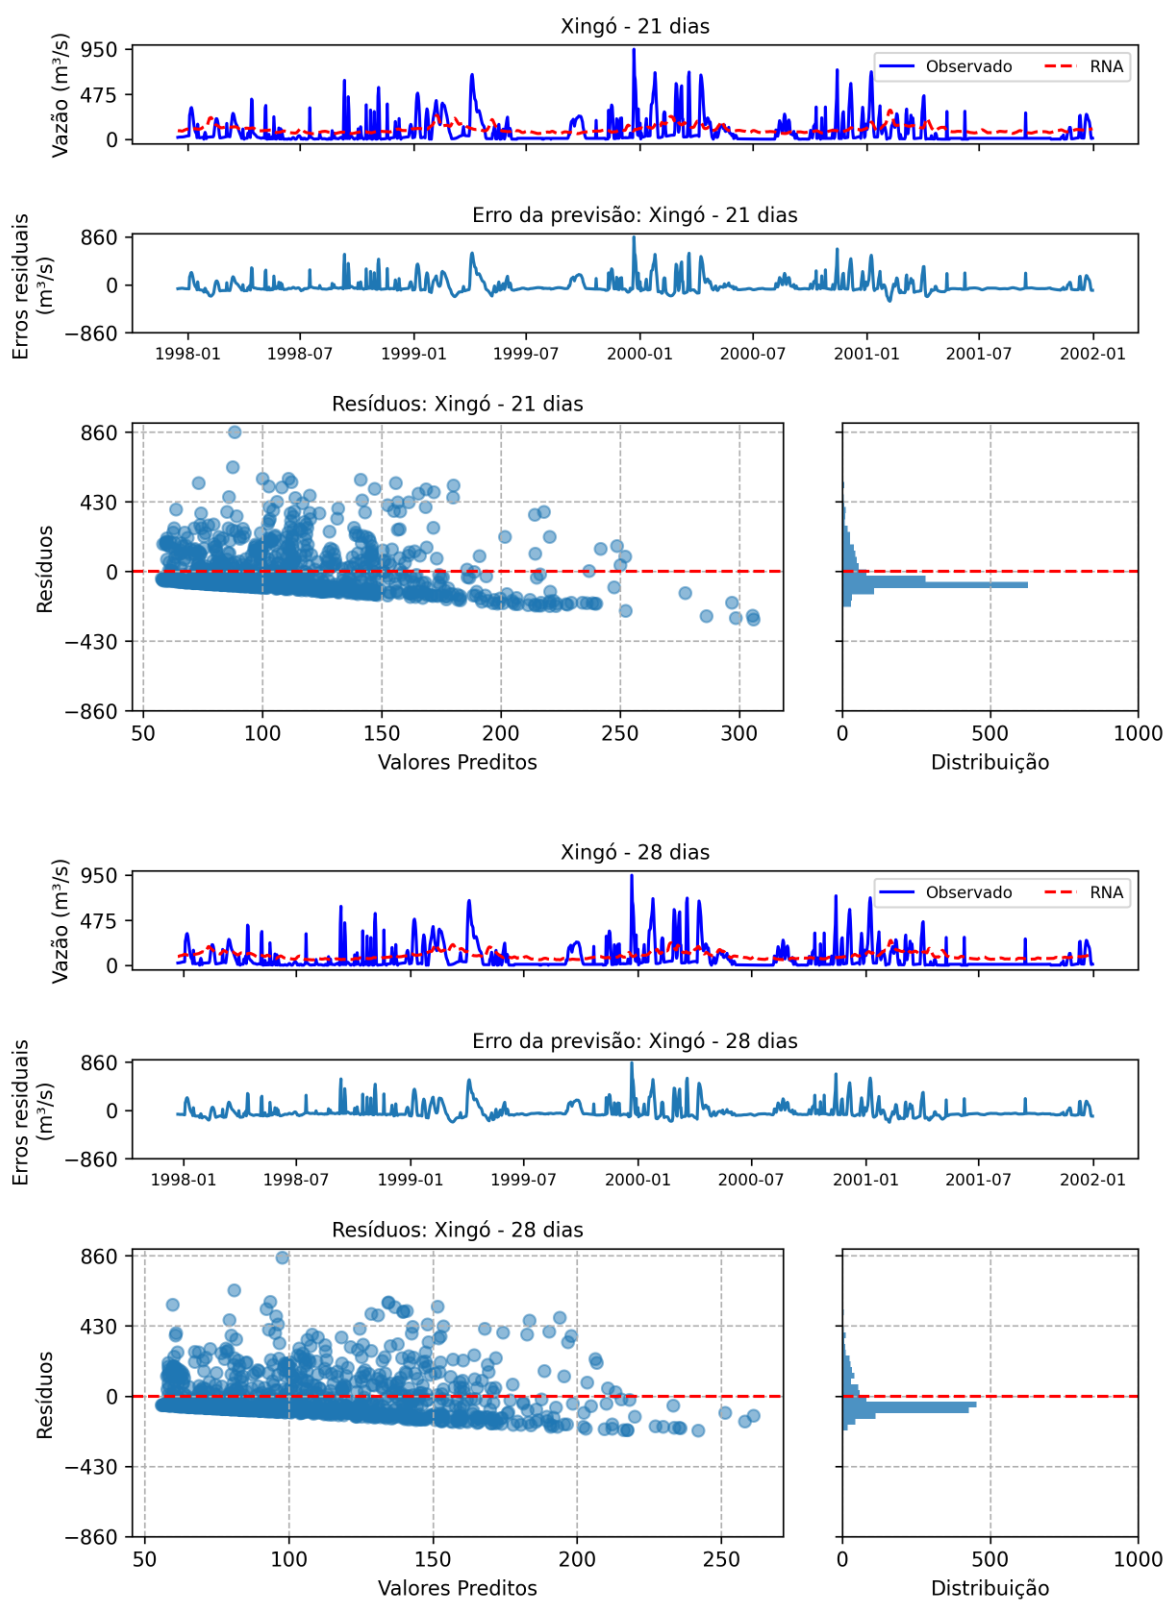
Fonte: Próprio autor

Figura 99 – Previsão RNA - Xingó 7 e 14 dias



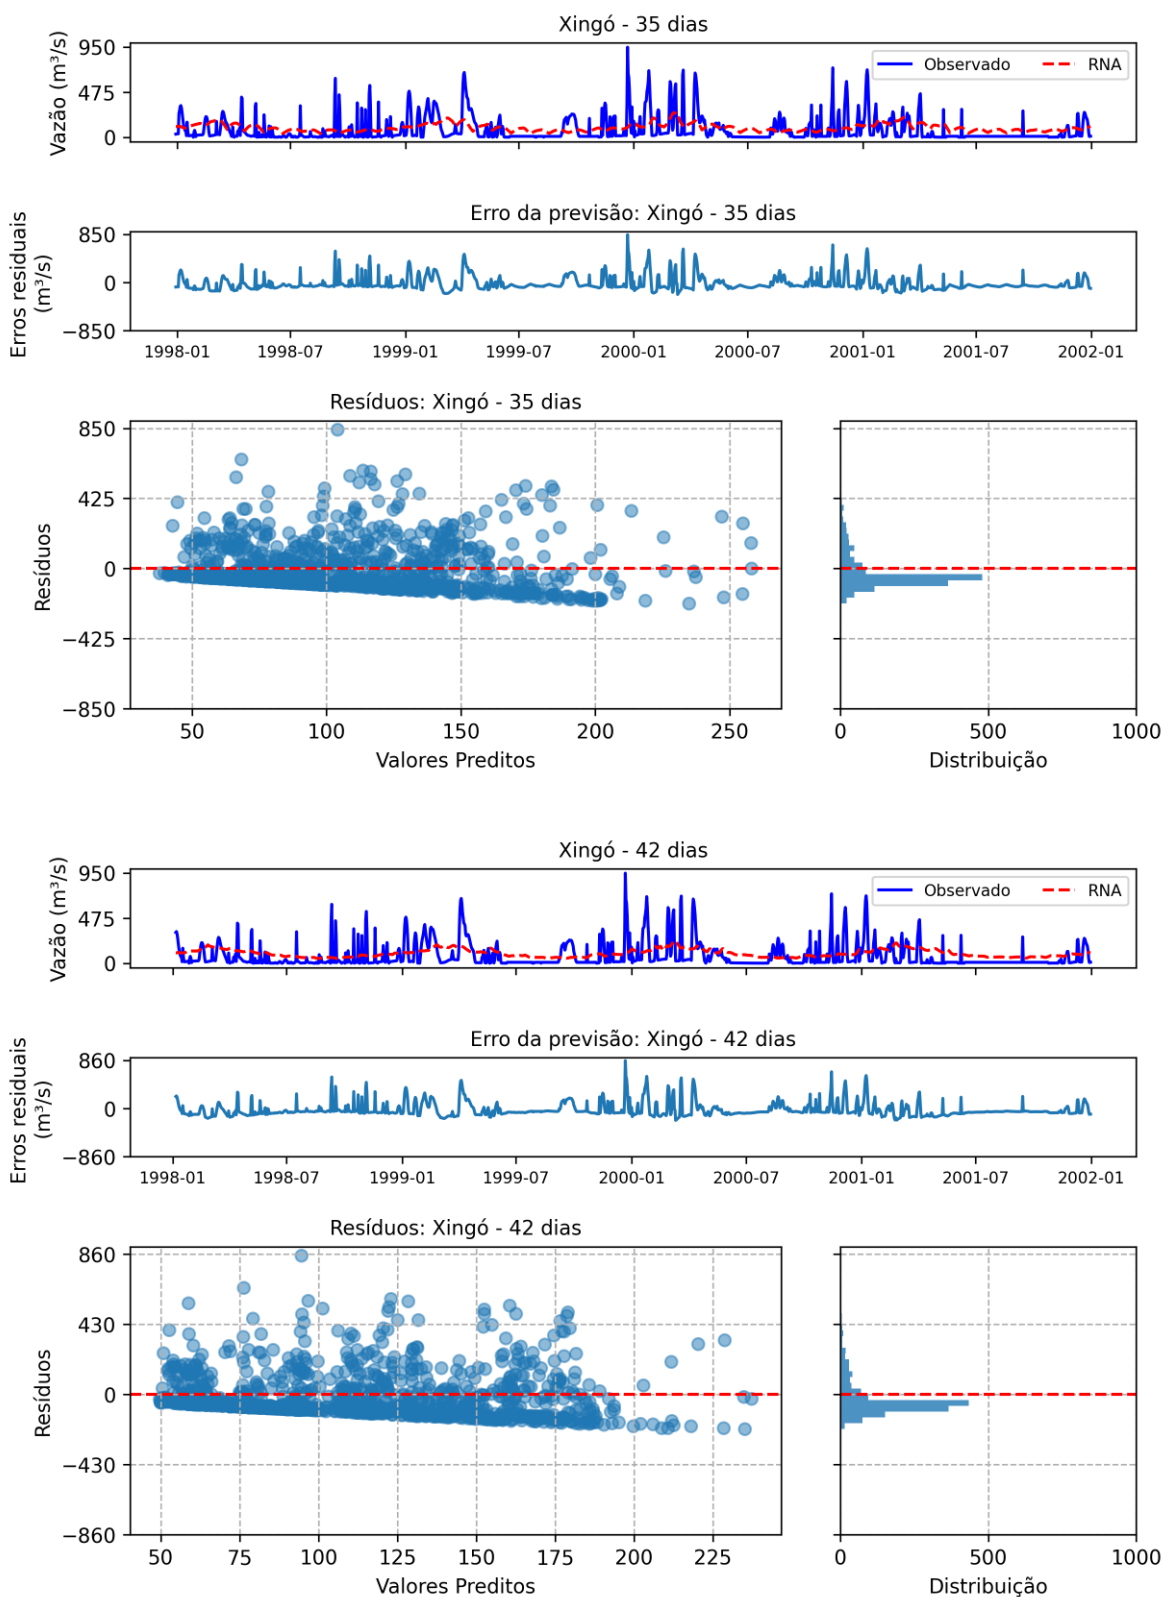
Fonte: Próprio autor

Figura 100 – Previsão RNA - Xingó 21 e 28 dias



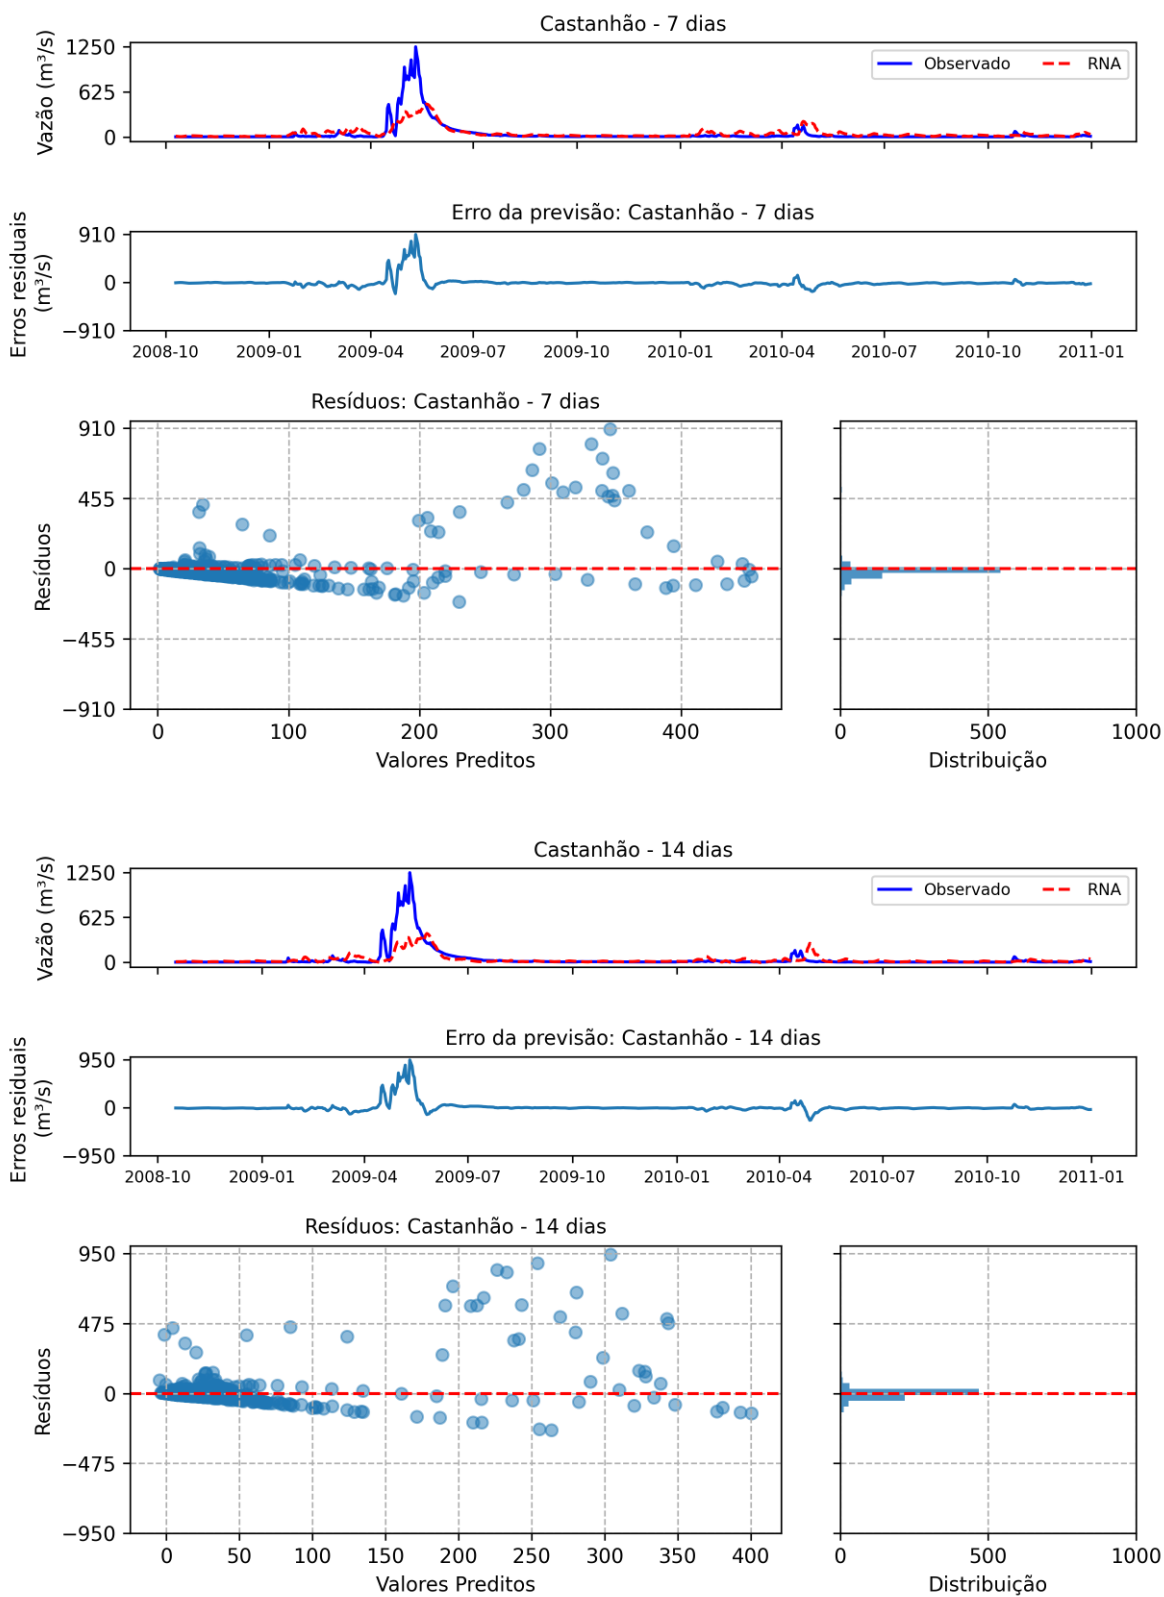
Fonte: Próprio autor

Figura 101 – Previsão RNA - Xingó 35 e 42 dias



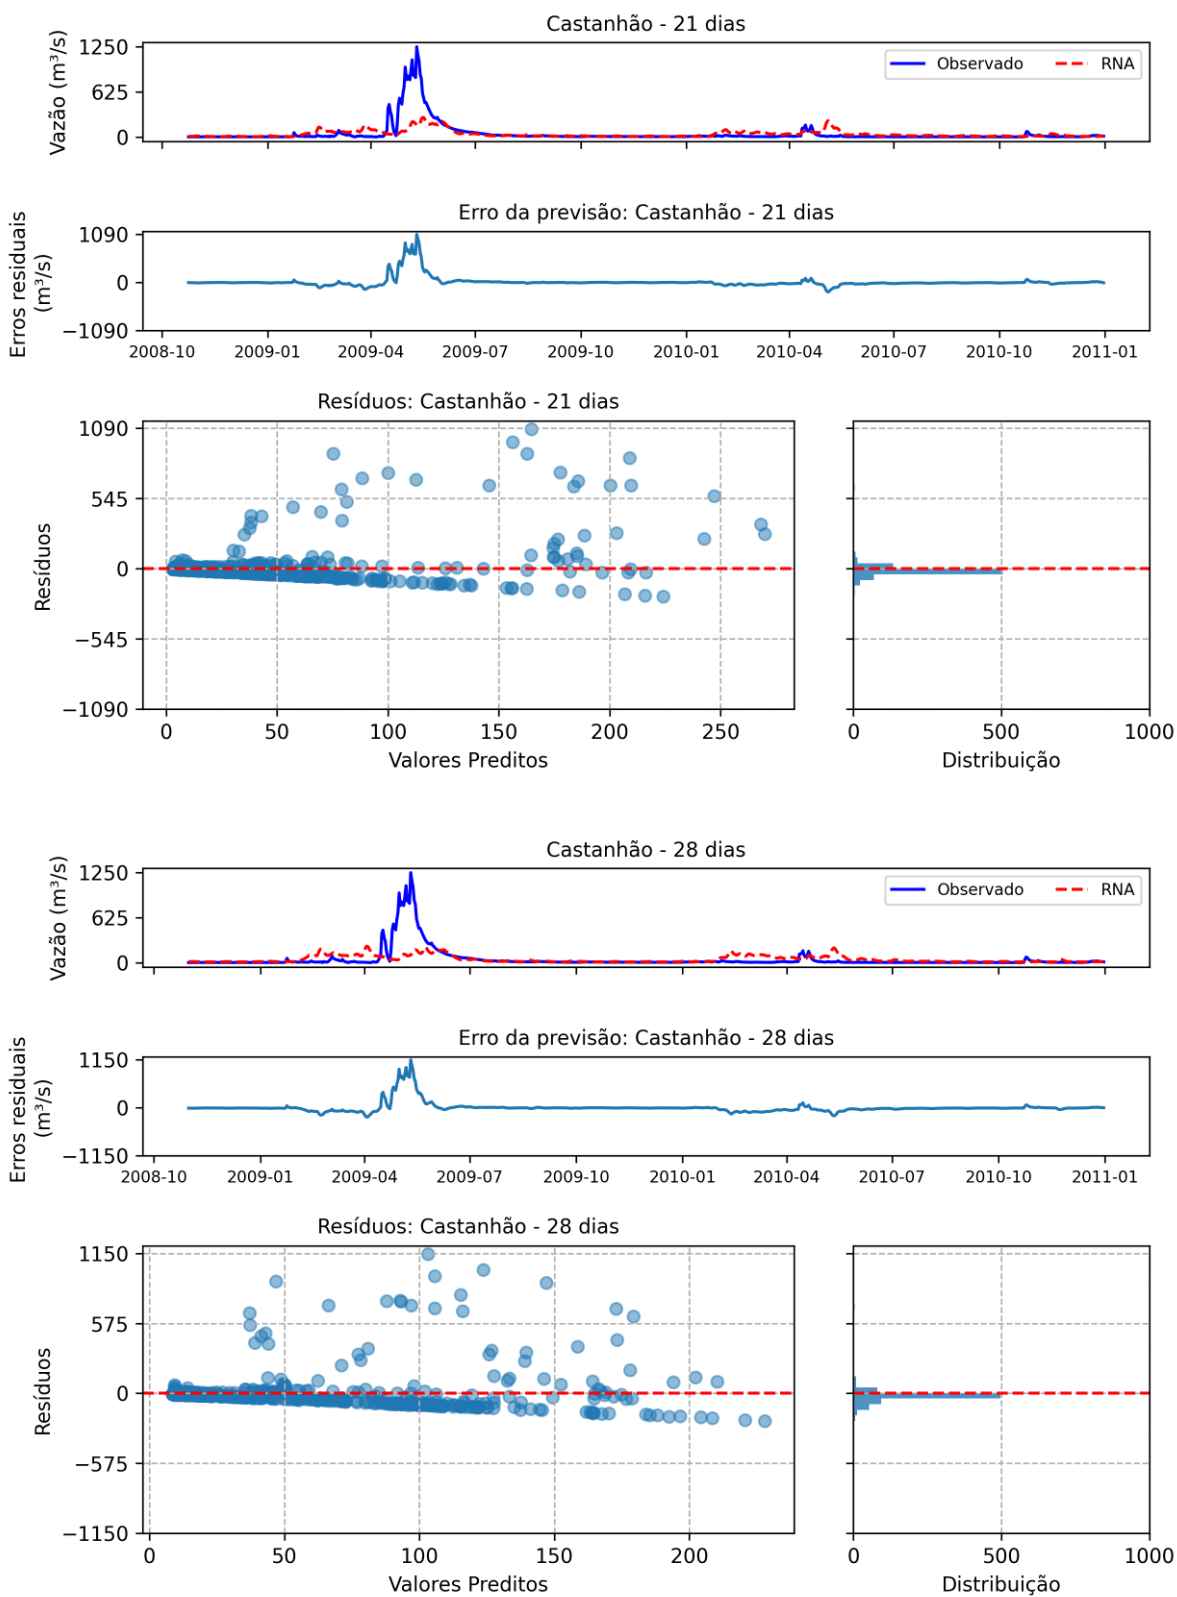
Fonte: Próprio autor

Figura 102 – Previsão RNA - Castanhão 7 e 14 dias



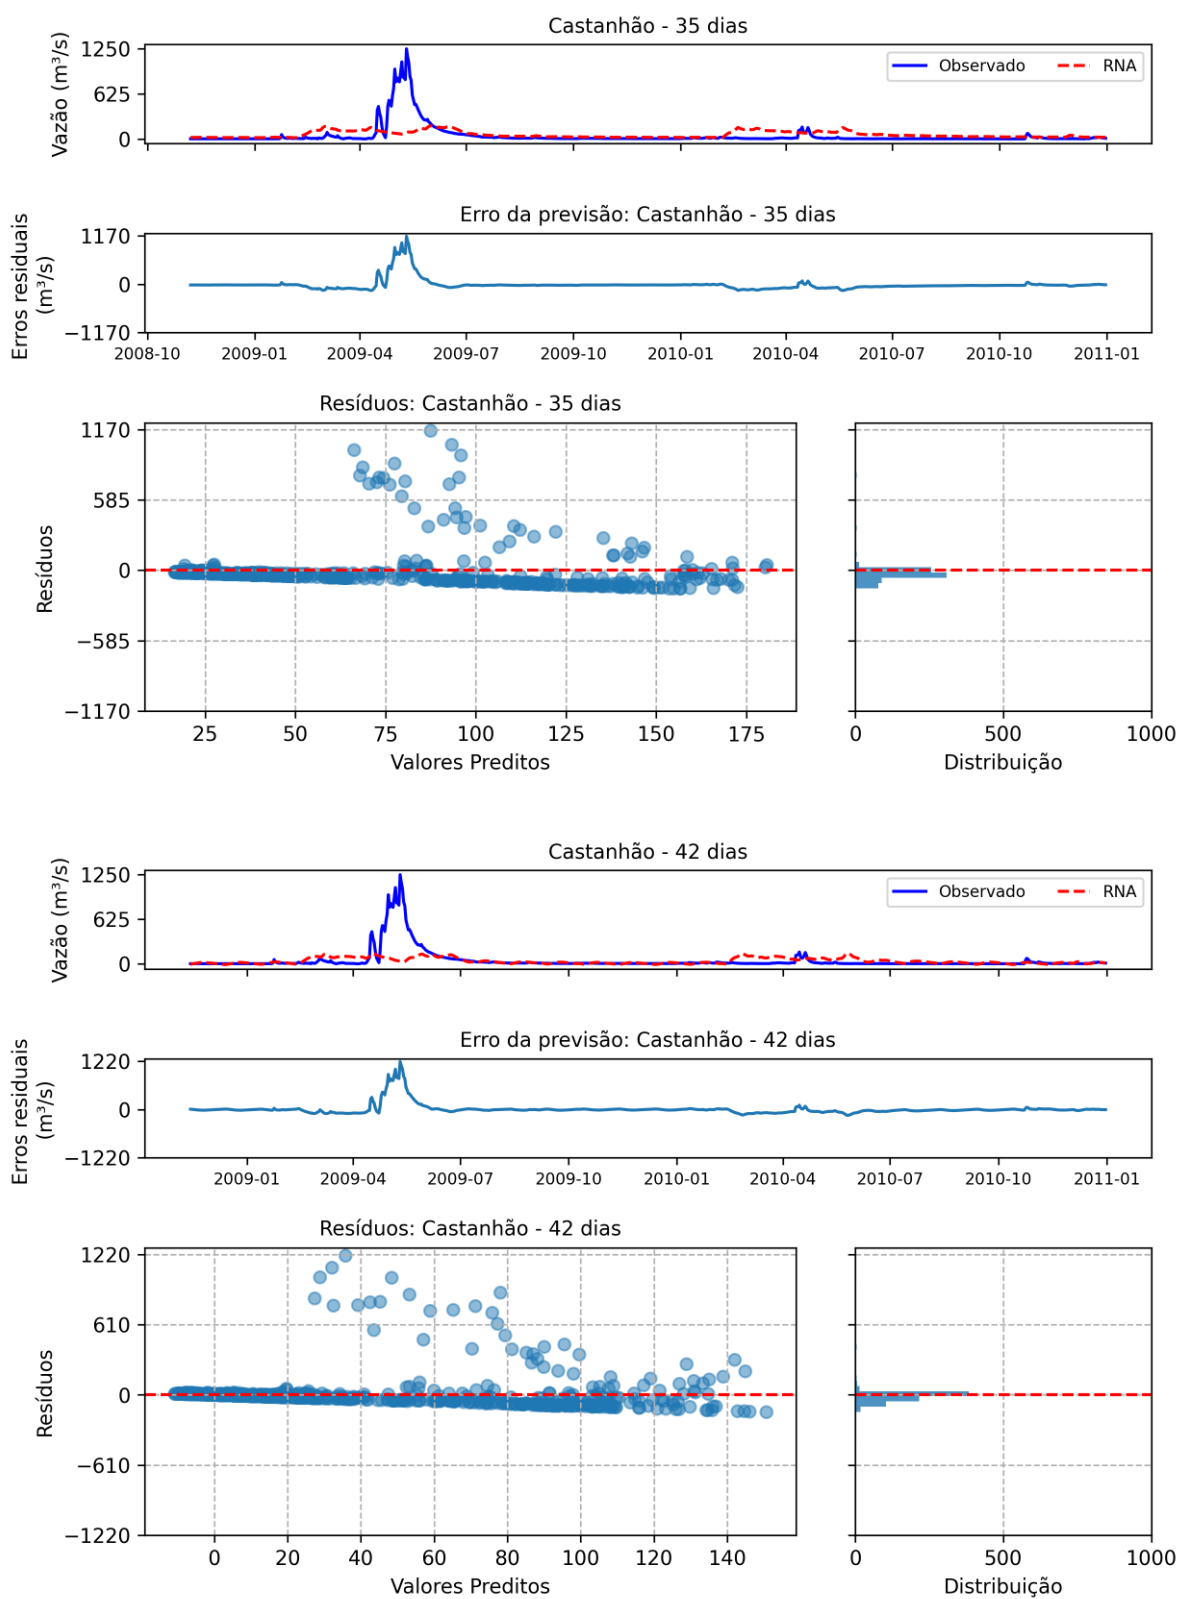
Fonte: Próprio autor

Figura 103 – Previsão RNA - Castanhão 21 e 28 dias



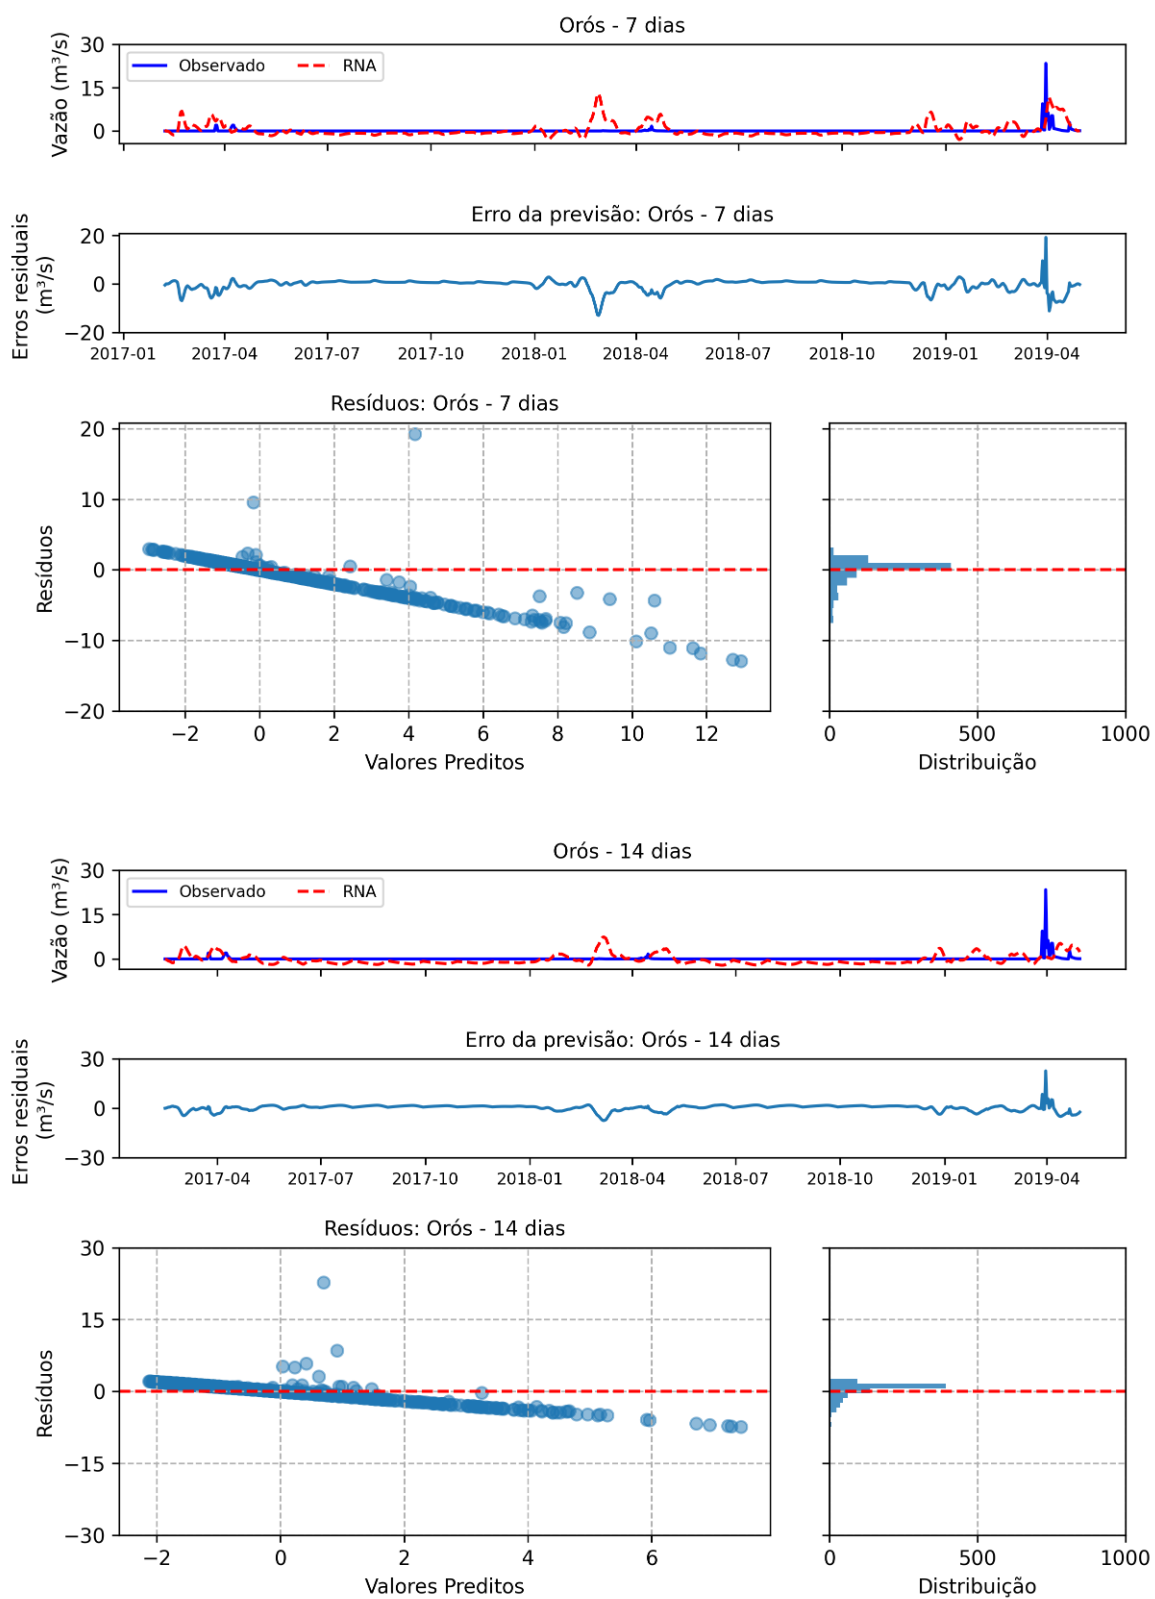
Fonte: Próprio autor

Figura 104 – Previsão RNA - Castanhão 35 e 42 dias



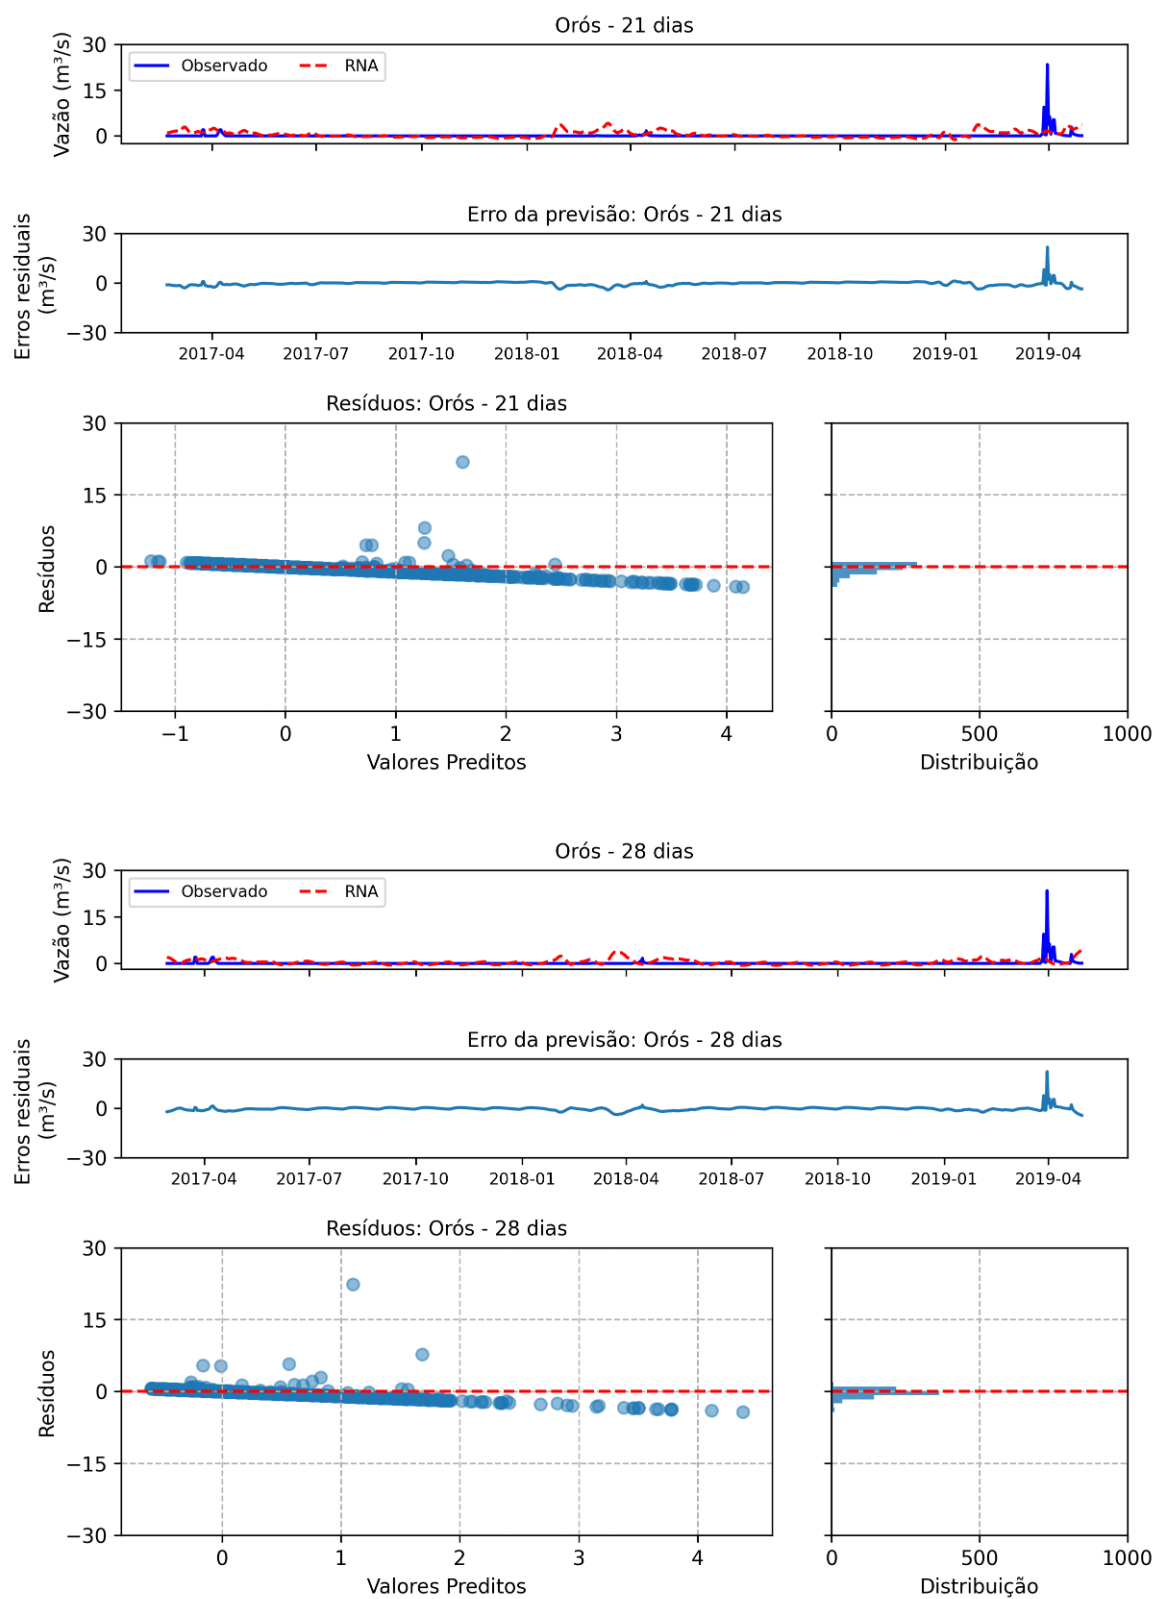
Fonte: Próprio autor

Figura 105 – Previsão RNA - Orós 7 e 14 dias



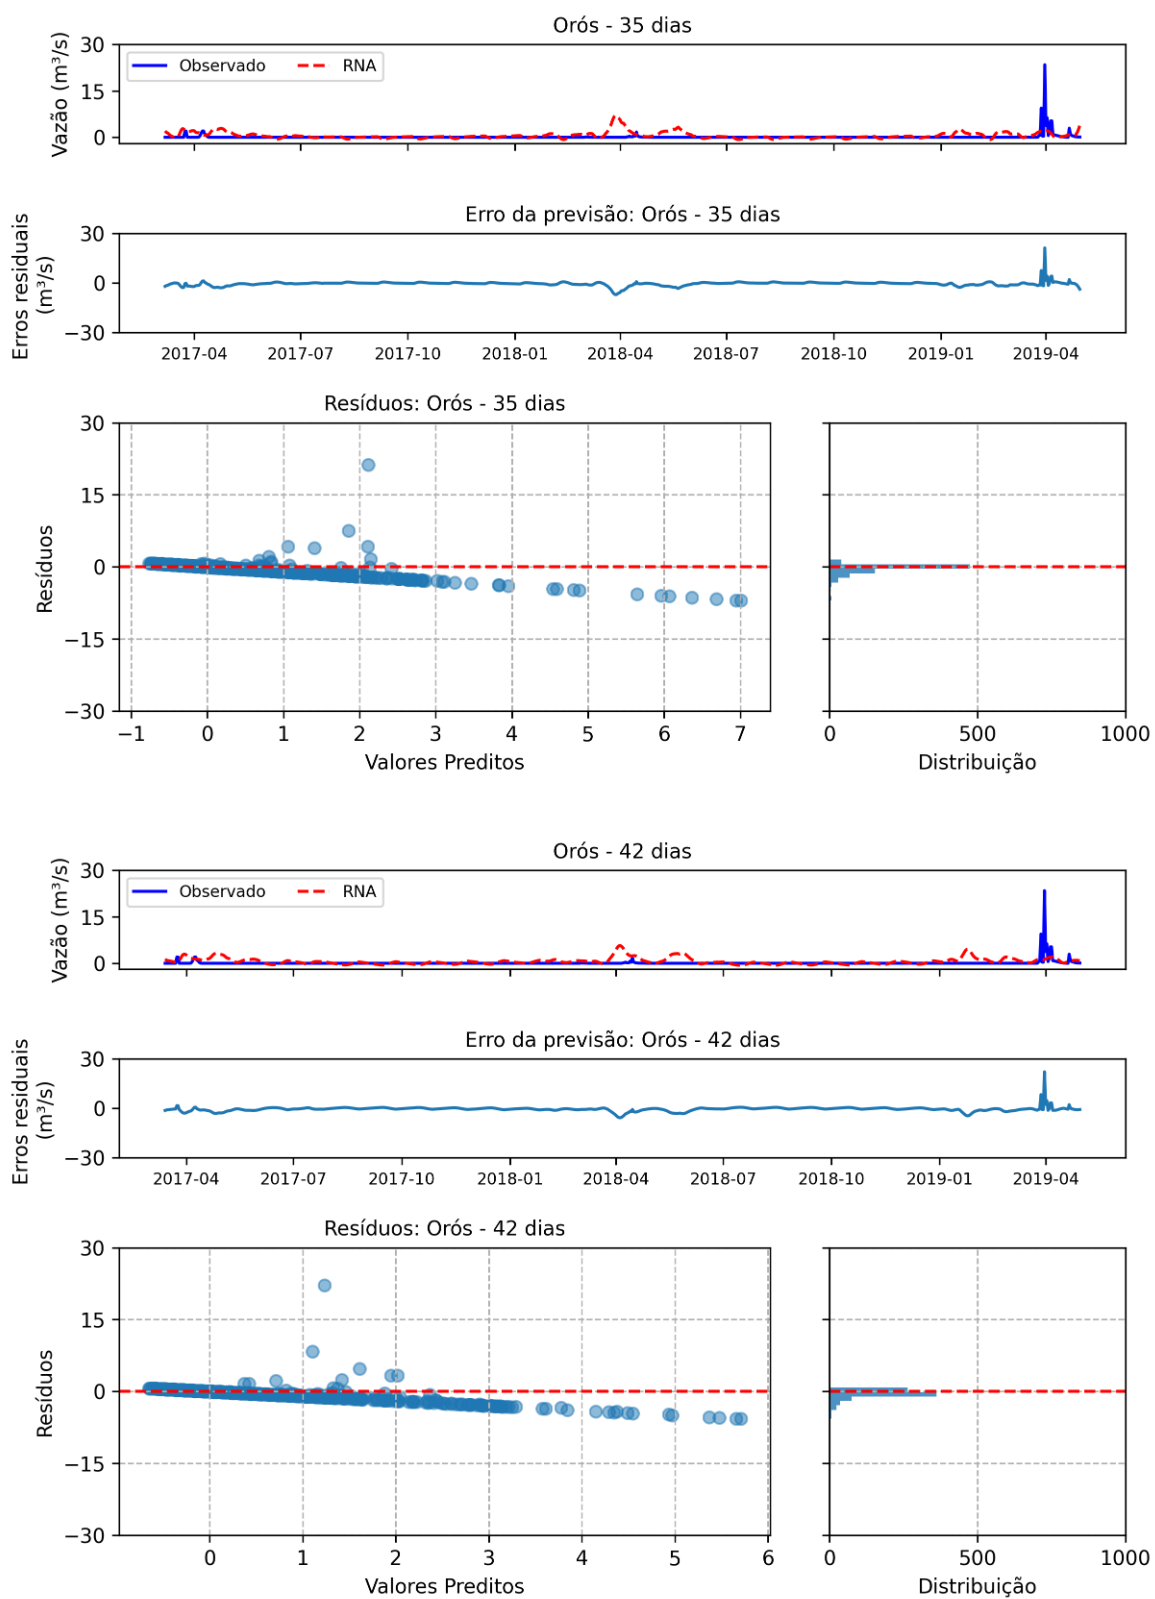
Fonte: Próprio autor

Figura 106 – Previsão RNA - Orós 21 e 28 dias



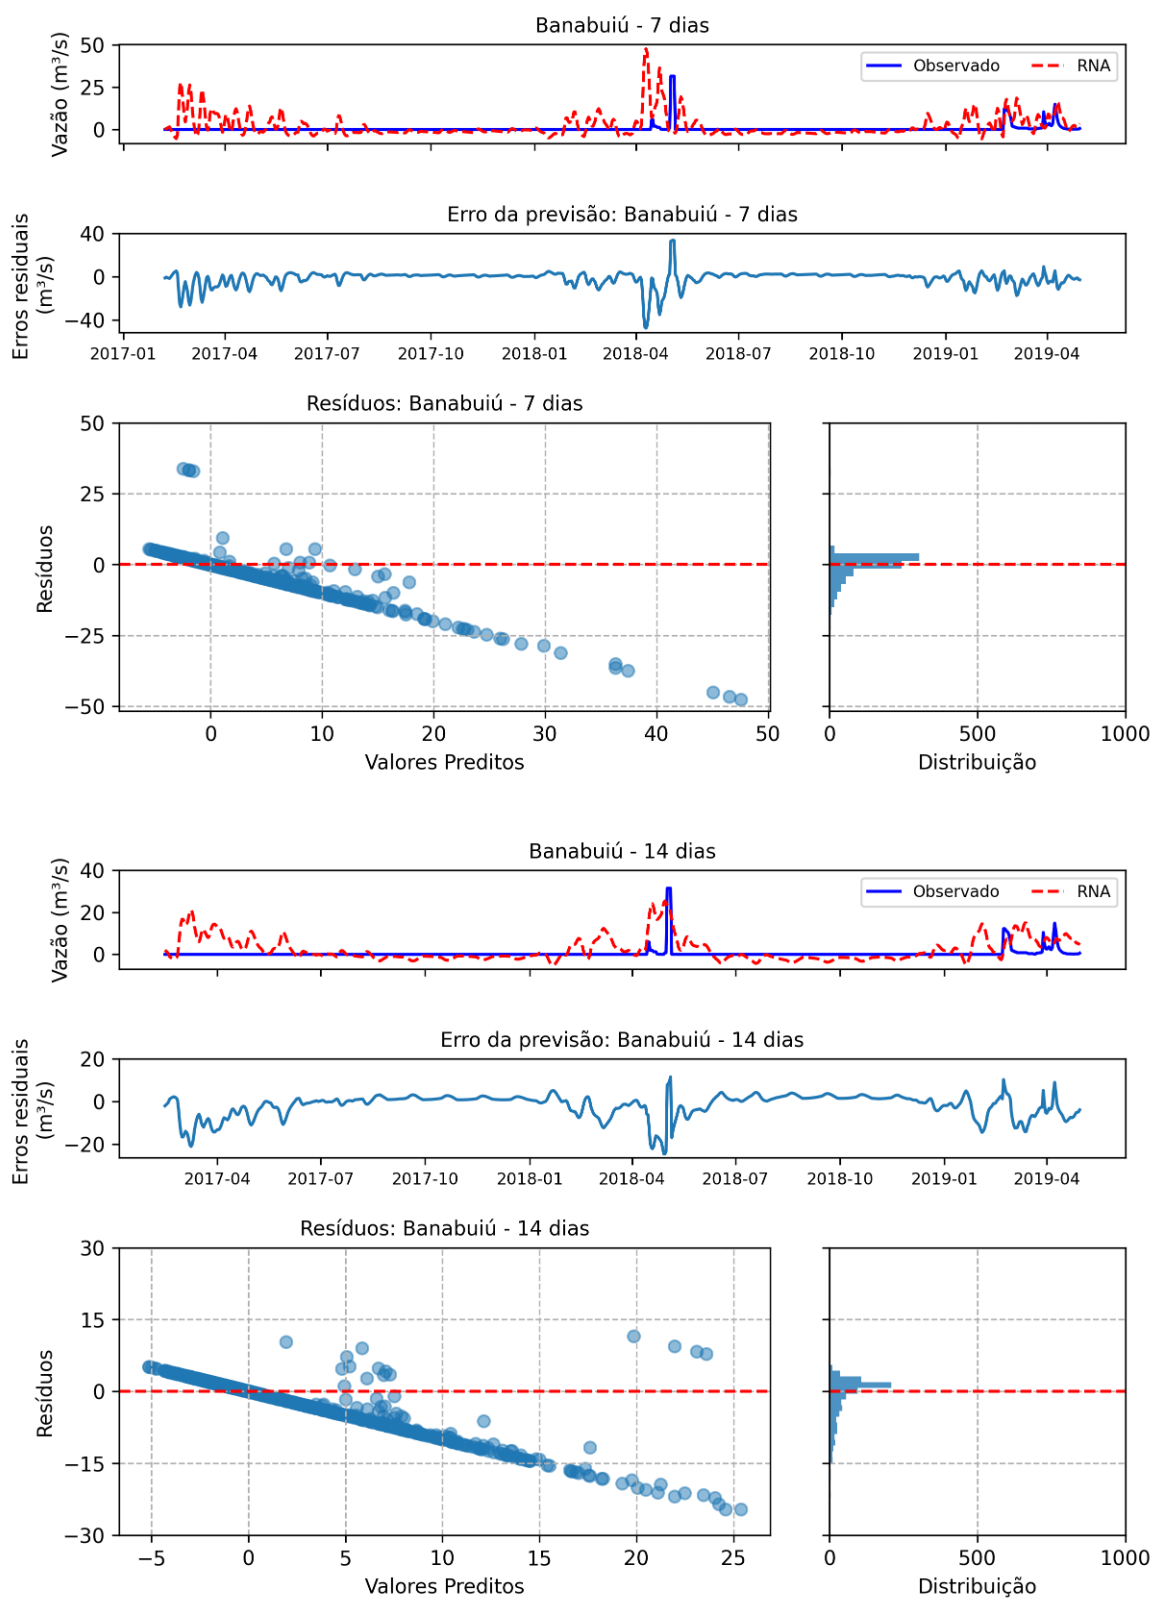
Fonte: Próprio autor

Figura 107 – Previsão RNA - Orós 35 e 42 dias



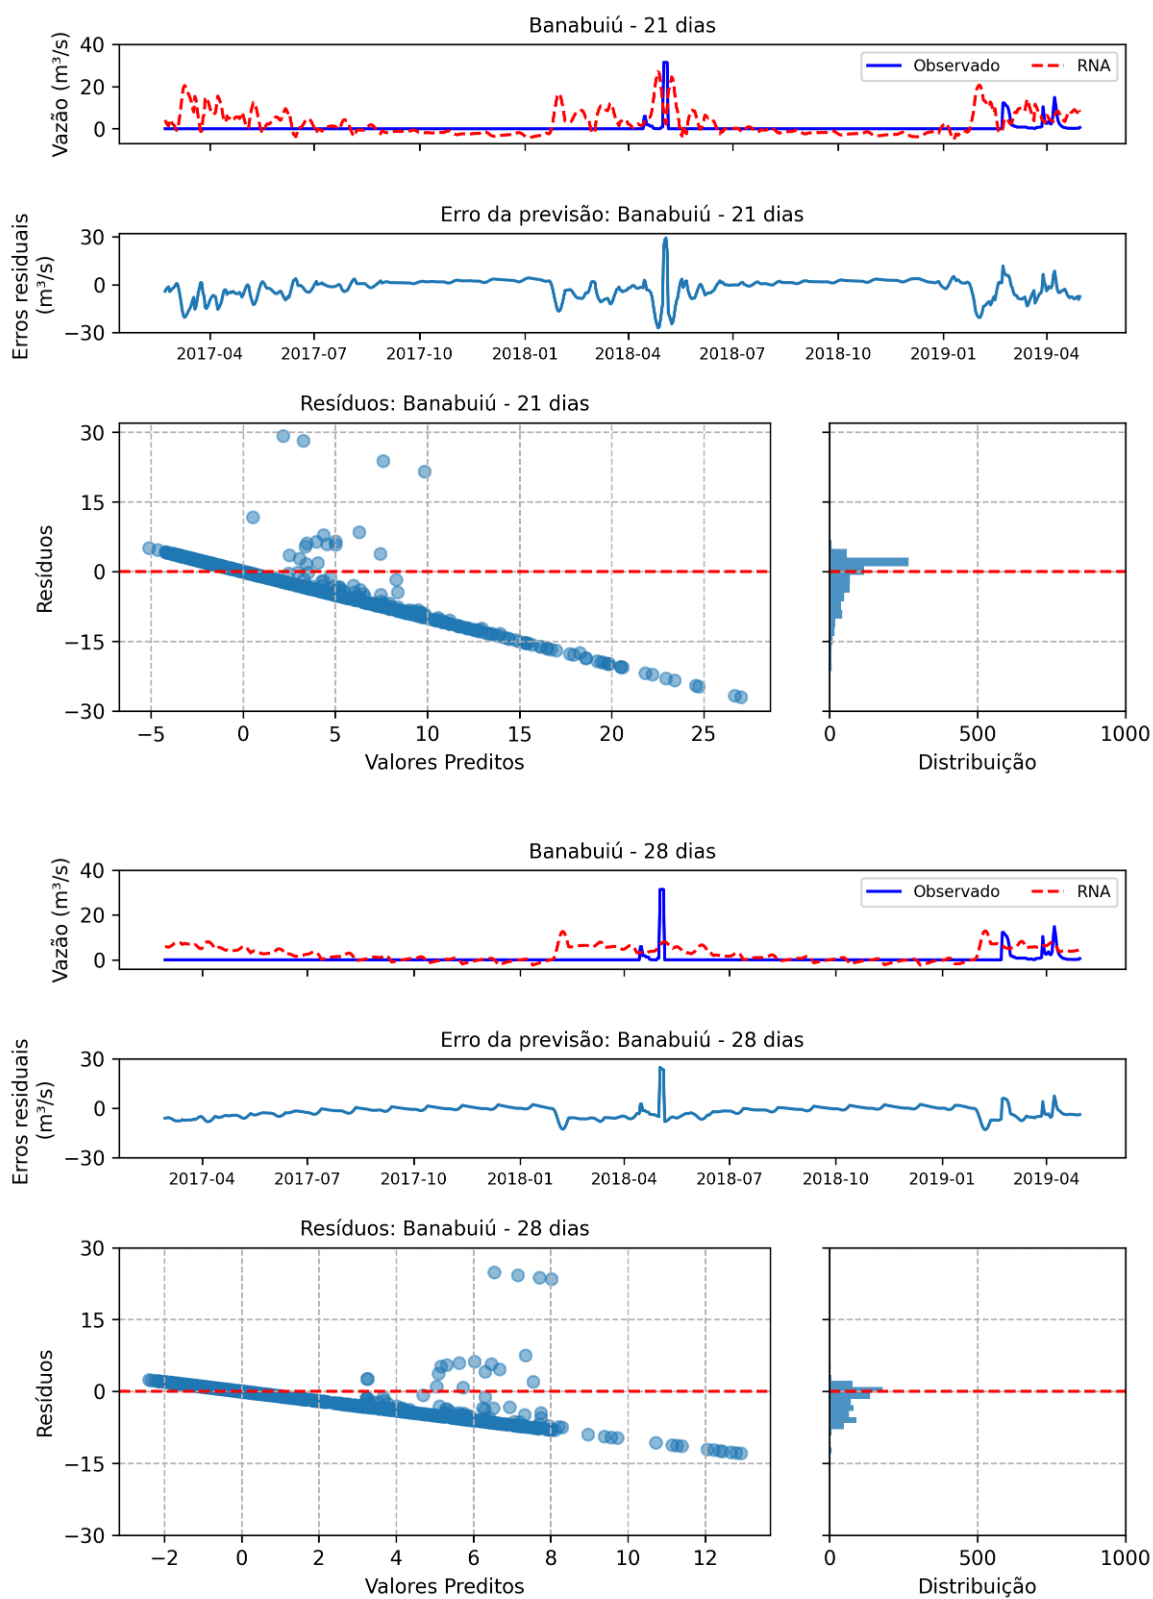
Fonte: Próprio autor

Figura 108 – Previsão RNA - Banabuiú 7 e 14 dias



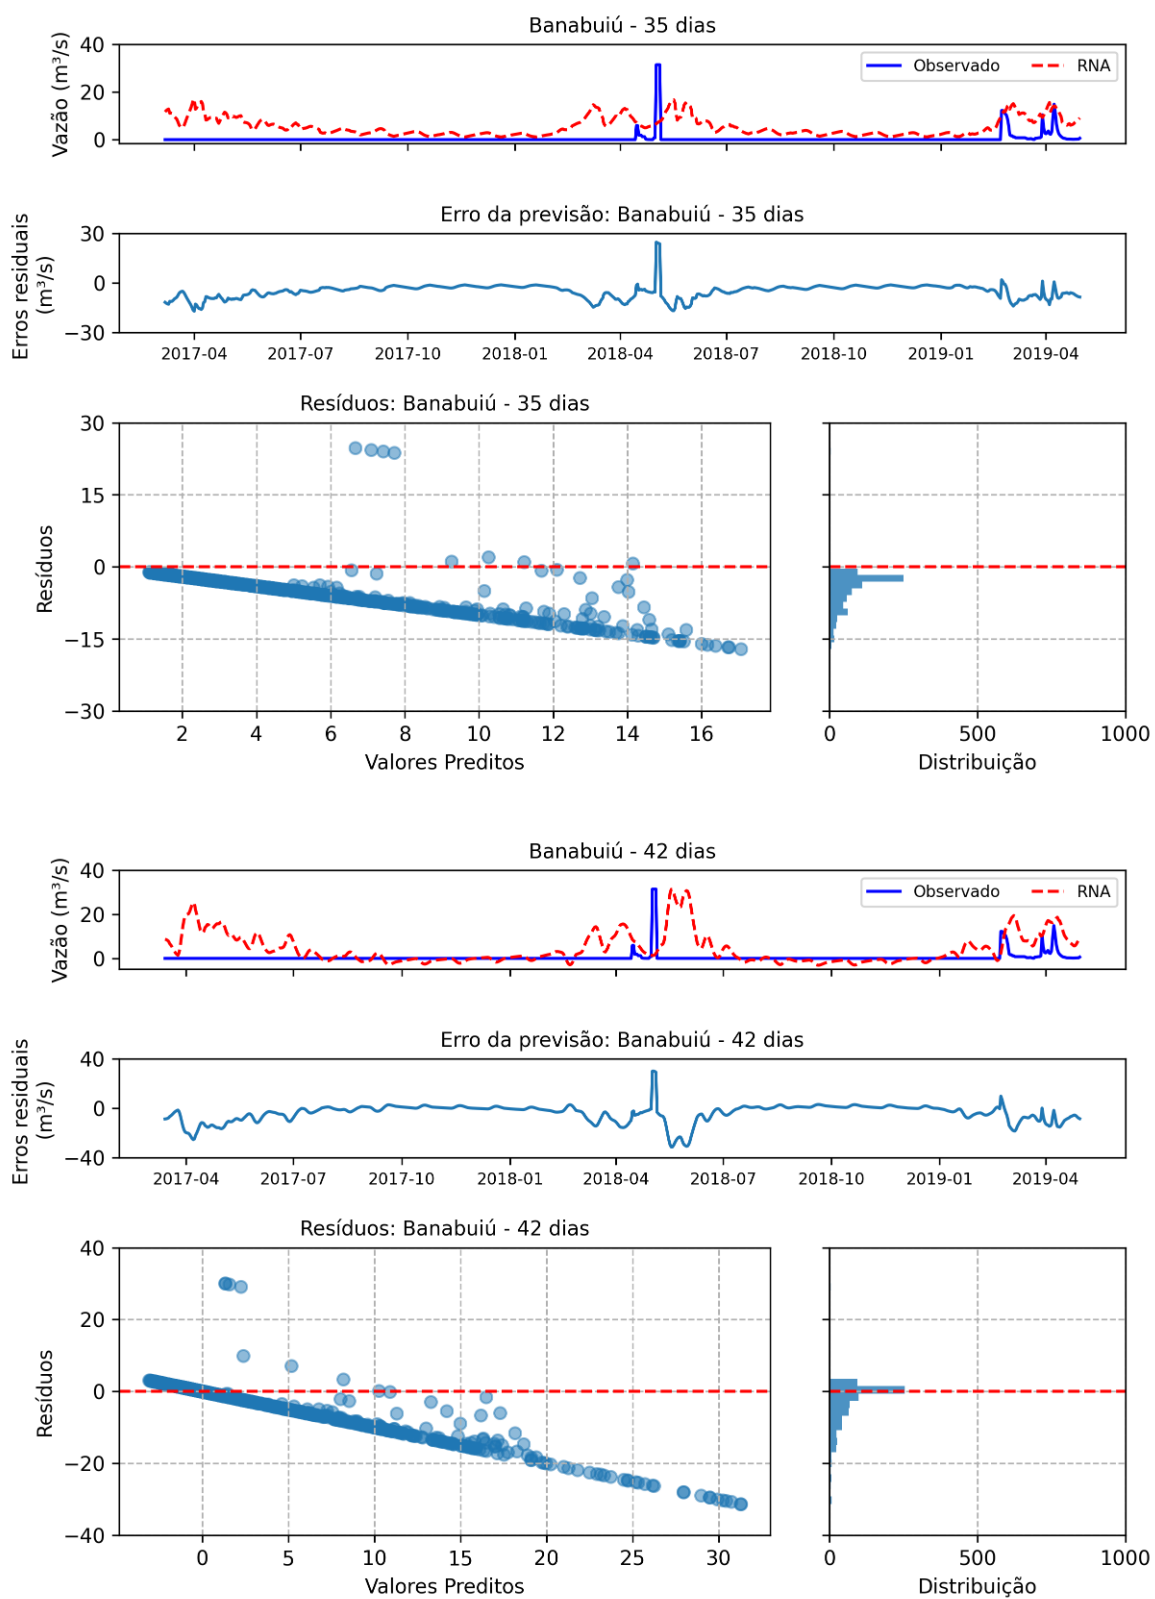
Fonte: Próprio autor

Figura 109 – Previsão RNA - Banabuiú 21 e 28 dias



Fonte: Próprio autor

Figura 110 – Previsão RNA - Banabuiú 35 e 42 dias



Fonte: Próprio autor

Tabela 22 – Previsões (RNA) - Orós

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	nan	nan	0.095	0.309	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-703.042	-37.76	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.627	4.293	2.386	3.935	0.842	1.001	1.061	0.954	0.888	0.755	0.678	2.373
14 dias	r	nan	nan	-0.02	-0.12	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-919.873	-12.326	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.17	1.518	2.729	2.307	1.224	1.217	1.344	1.388	1.381	1.305	1.246	1.414
21 dias	r	nan	nan	-0.043	-0.209	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-502.133	-5.517	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.457	1.386	2.017	1.614	0.877	0.41	0.21	0.196	0.302	0.411	0.486	0.572
28 dias	r	nan	nan	0.067	-0.326	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-265.934	-3.101	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	104	1.469	1.28	1.019	0.413	0.376	0.371	0.374	0.364	0.367	0.427	
35 dias	r	nan	nan	0.098	-0.166	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-321.191	-5.032	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.04	0.888	1.834	1.552	1.51	0.293	0.294	0.274	0.246	0.262	0.246	0.282
42 dias	r	nan	nan	0.119	-0.119	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-93.179	-9.997	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.648	0.946	1.027	2.096	1.874	0.522	0.383	0.341	0.338	0.341	0.37	0.427

Fonte: Elaborado pelo Autor, 2023

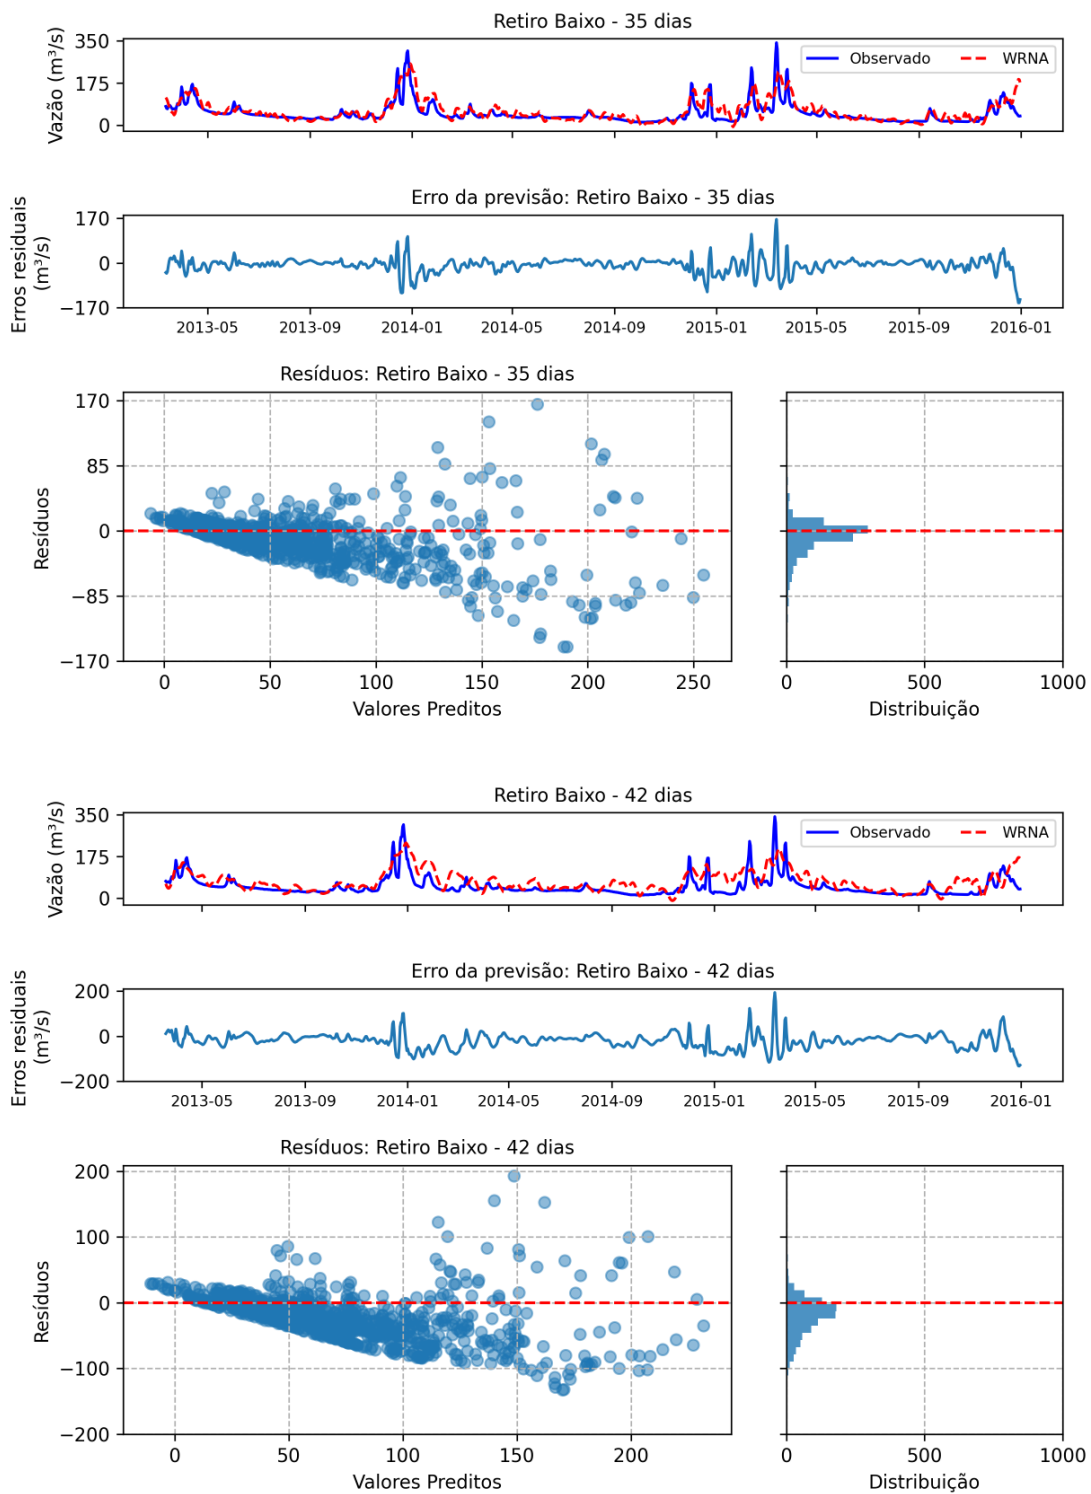
Tabela 23 – Previsões (RNA) - Banabuiú

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	nan	-0.005	-0.124	0.28	-0.277	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-44.335	-40.461	-81.984	-0.808	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	7.19	11.233	8.578	10.787	13.277	2.533	1.93	1.84	1.687	1.436	1.216	1.841
14 dias	r	nan	0.058	-0.181	0.06	0.785	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-11.836	-61.806	-71.931	0.446	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	3.208	6.217	10.557	10.113	7.35	3.092	1.651	2.154	2.13	1.904	1.728	1.835
21 dias	r	nan	-0.153	-0.362	-0.101	0.268	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-10.604	-50.405	-70.511	-0.053	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	5.801	6.169	9.551	10.014	10.131	4.008	1.379	1.01	1.514	2.026	2.494	2.787
28 dias	r	nan	-0.33	-0.074	0.126	0.749	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-16.71	-18.821	-14.098	0.202	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.975	7.983	5.931	4.601	8.821	3.557	1.879	1.33	0.974	0.856	0.963	1.027
35 dias	r	nan	0.866	0.001	0.266	-0.212	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	0.039	-11.203	-74.344	-0.585	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	2.08	3.969	9.628	10.279	12.429	6.134	4.145	3.326	2.869	2.451	2.175	2.086
42 dias	r	nan	0.001	0.232	0.211	-0.437	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-0.339	-8.81	-135.993	-2.459	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	2.834	4.685	8.928	13.86	18.363	8.289	3.478	1.359	1.752	1.548	1.202	0.82

Fonte: Elaborado pelo Autor, 2023

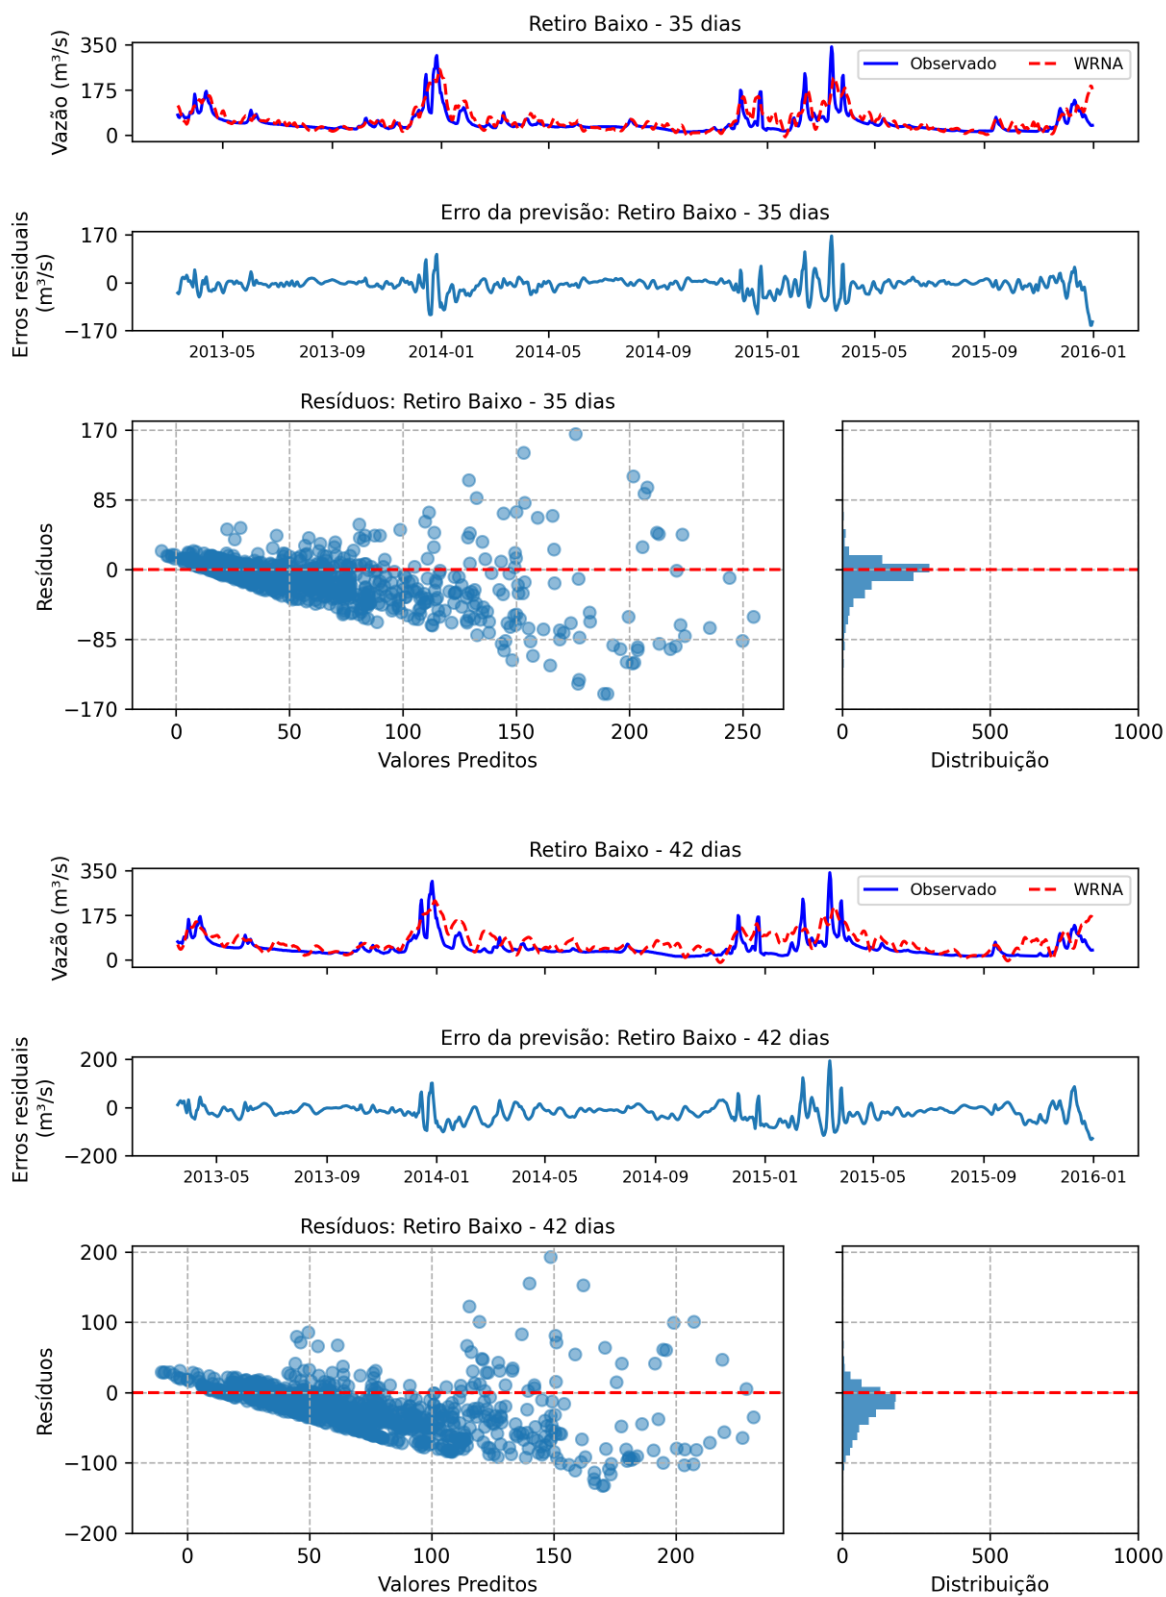
ANEXO C – REDES NEURAIS -WAVELETS

Figura 111 – Previsão WRNA - Retiro Baixo 35 e 42 dias



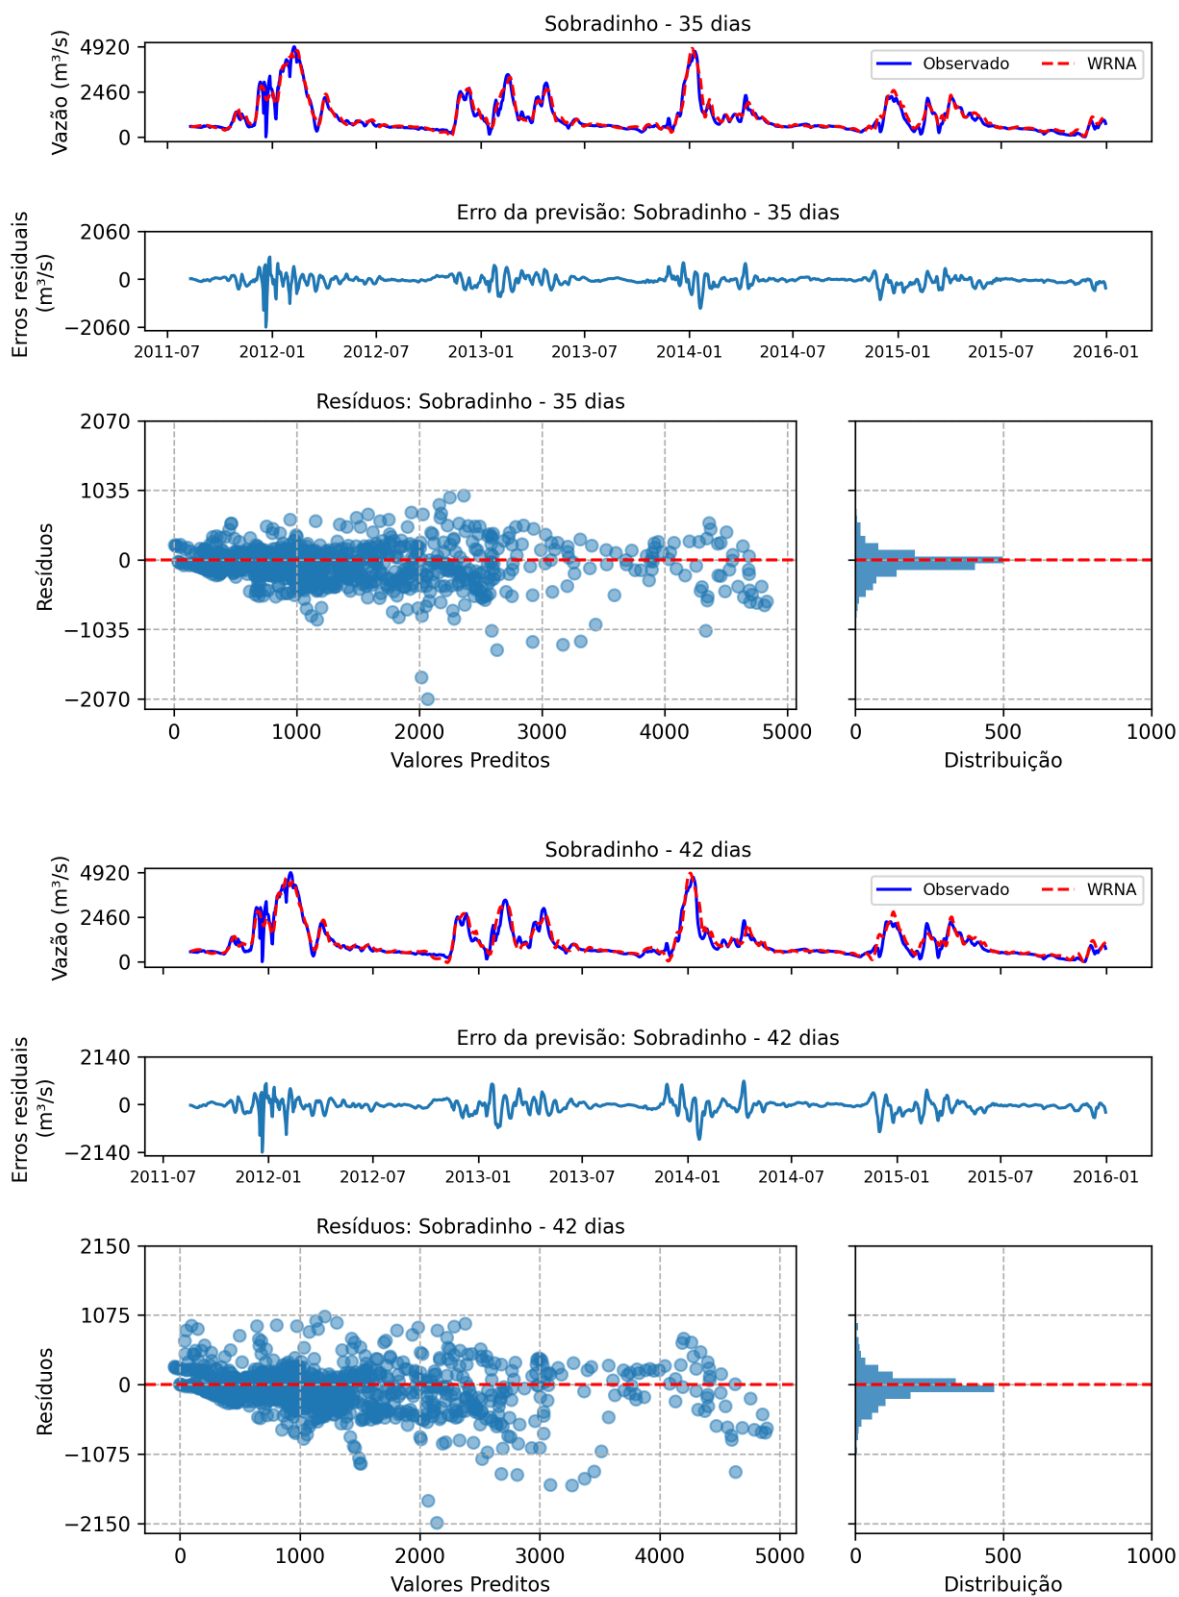
Fonte: Próprio autor

Figura 112 – Previsão WRNA - Retiro Baixo 35 e 42 dias



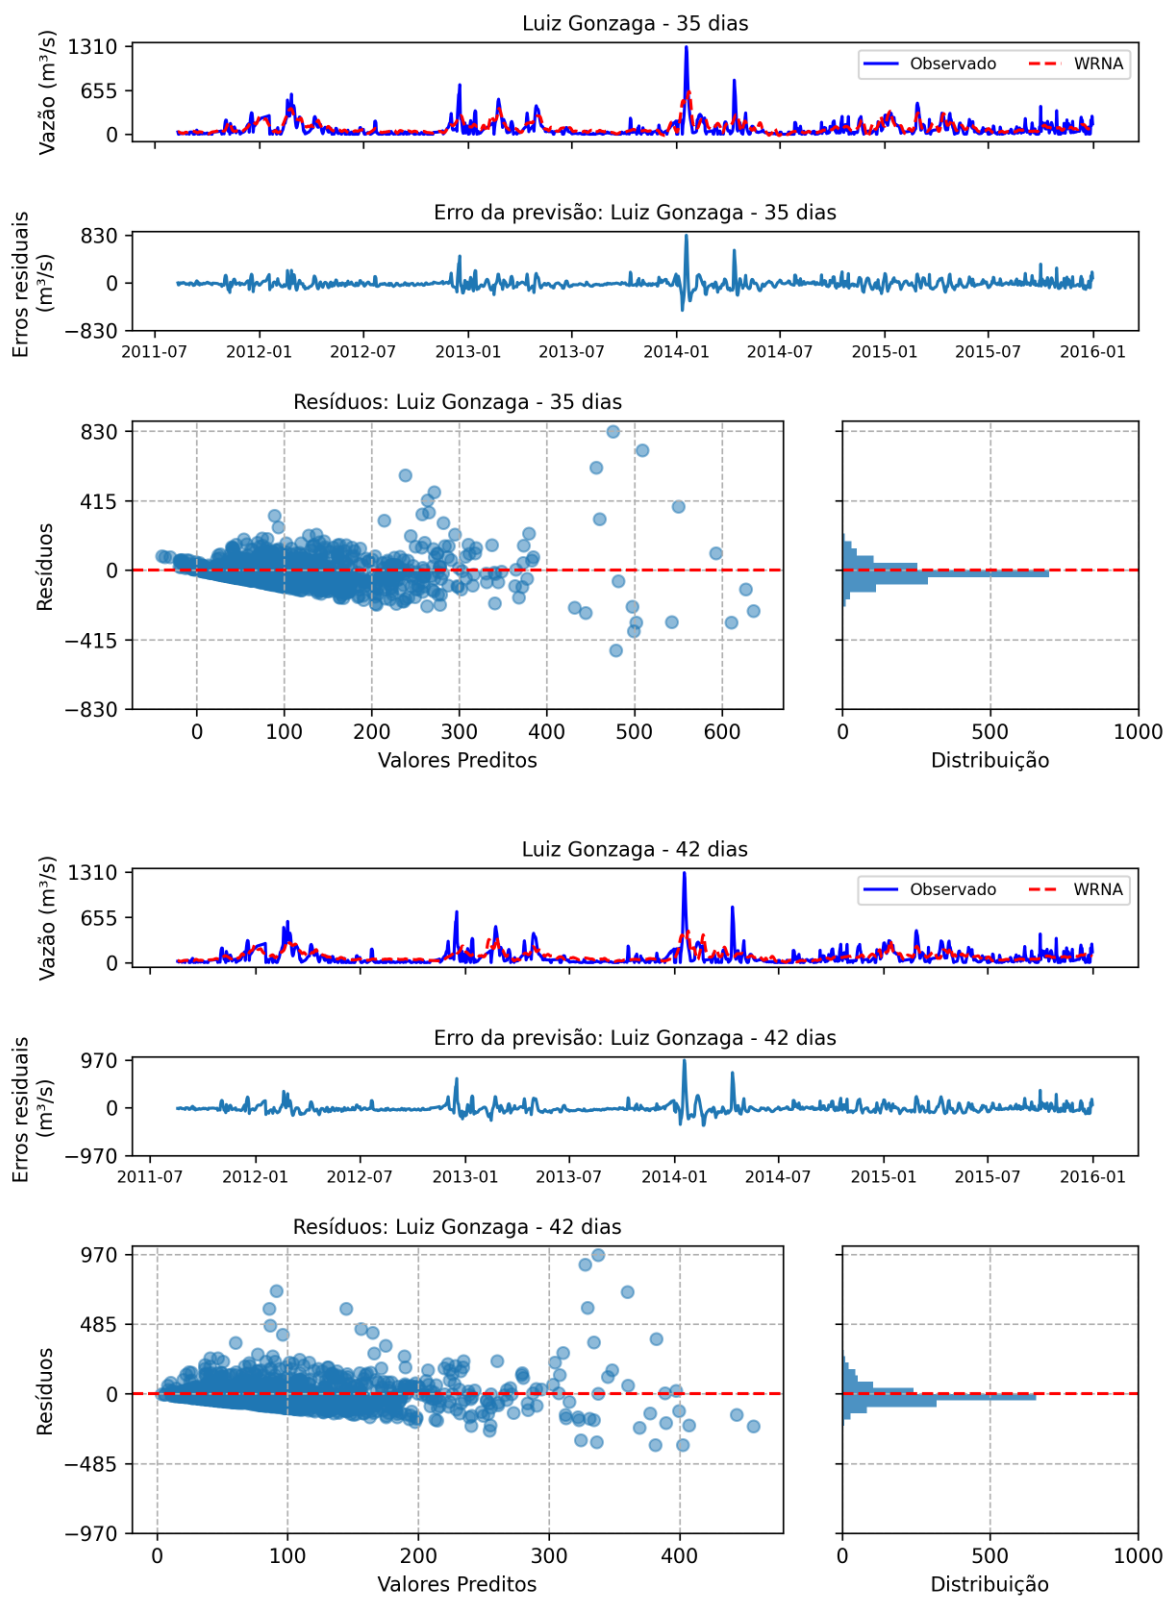
Fonte: Próprio autor

Figura 113 – Previsão WRNA - Sobradinho 35 e 42 dias



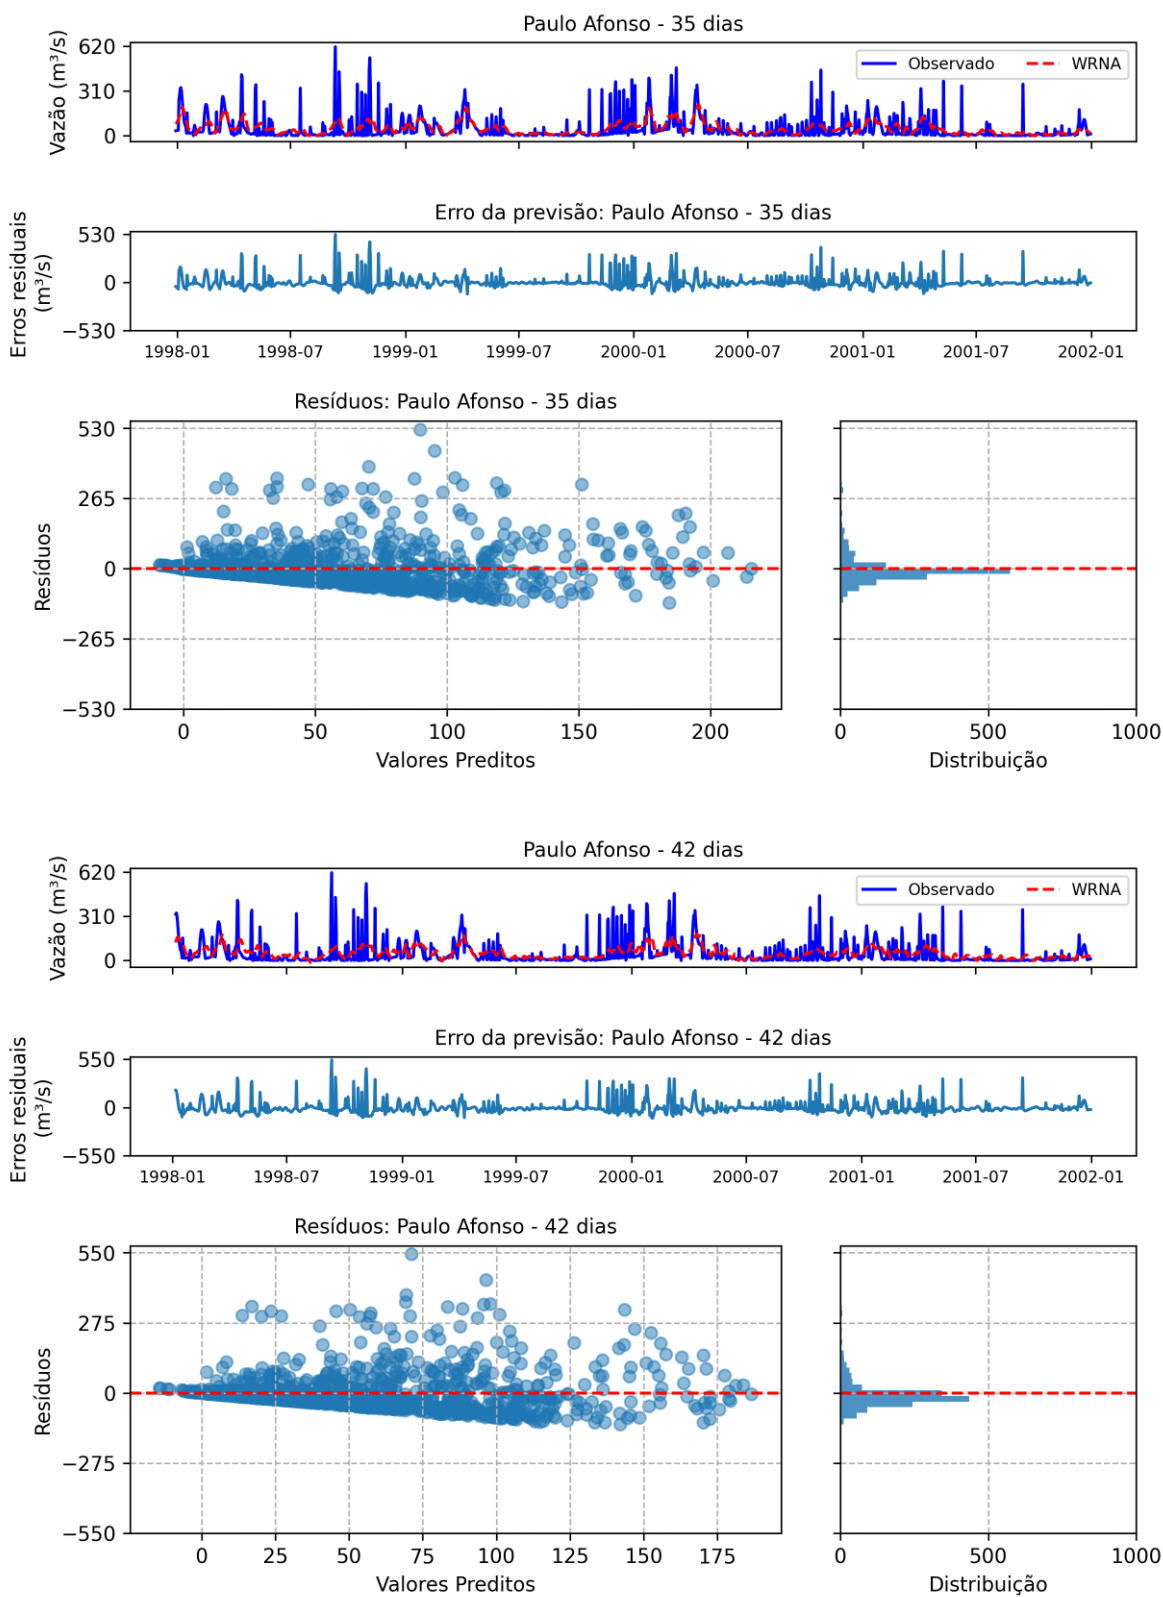
Fonte: Próprio autor

Figura 114 – Previsão WRNA - Luiz Gonzaga 35 e 42 dias



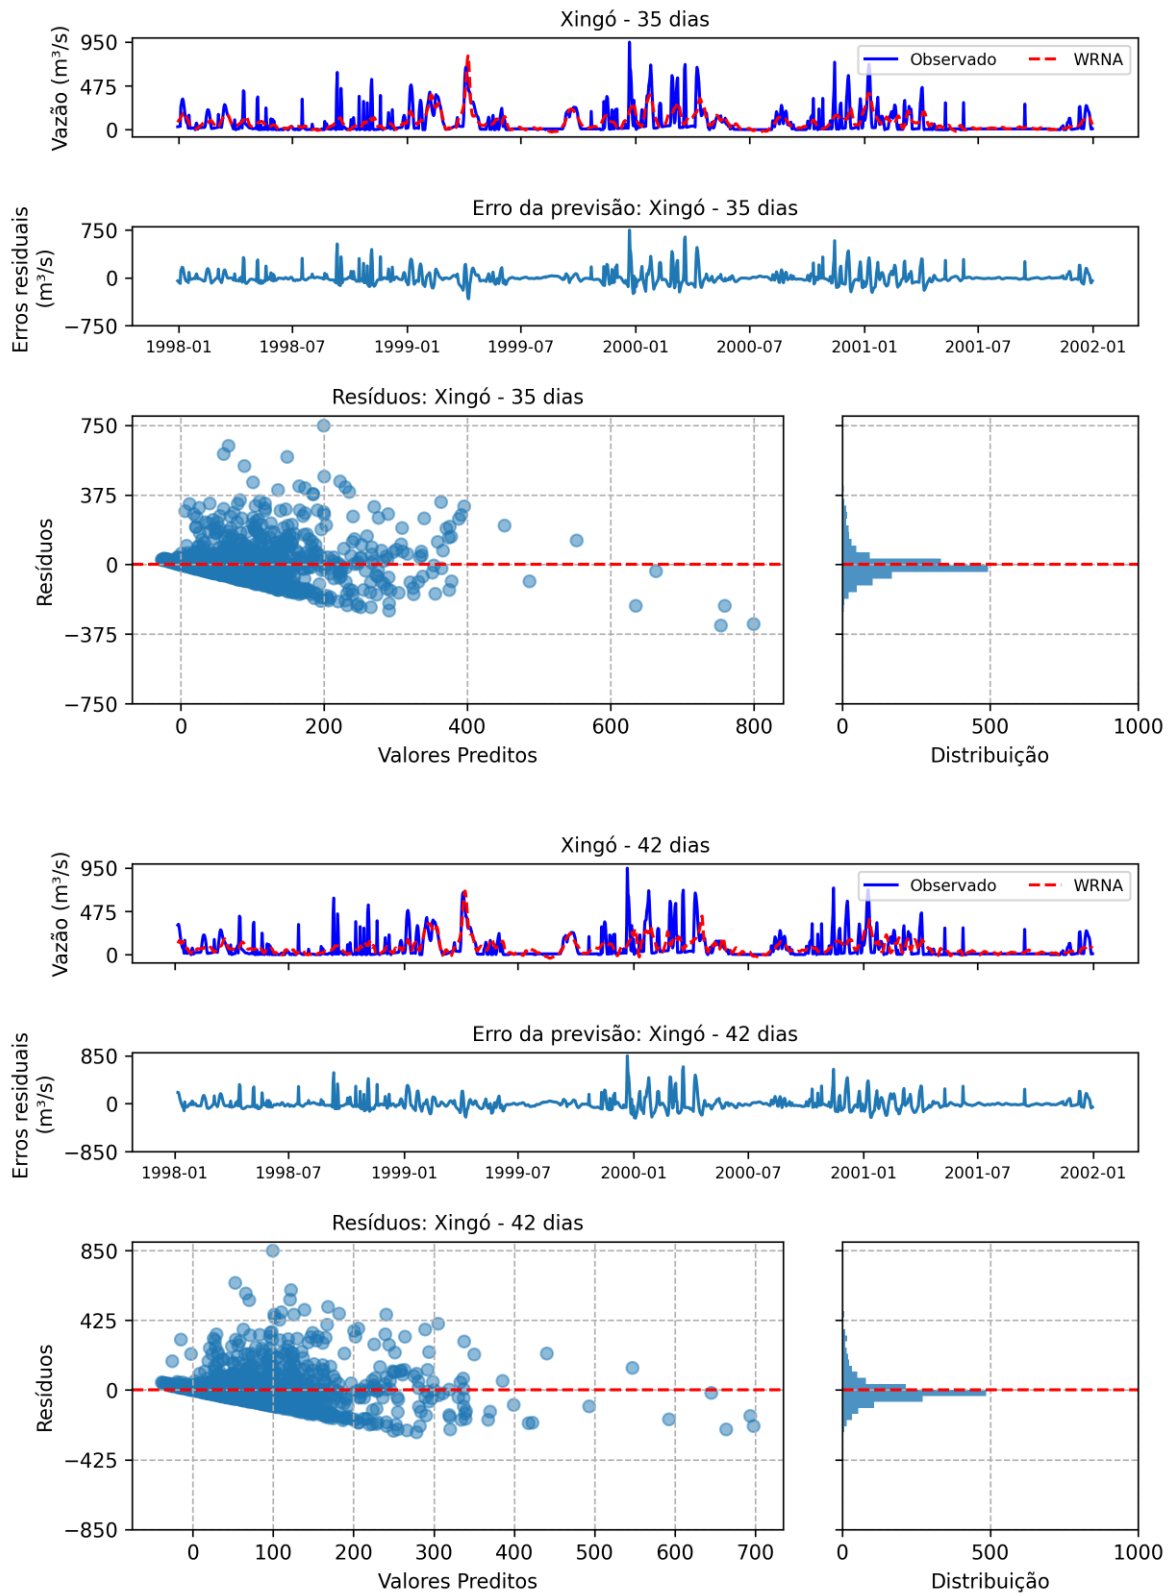
Fonte: Próprio autor

Figura 115 – Previsão WRNA - Paulo Afonso 35 e 42 dias



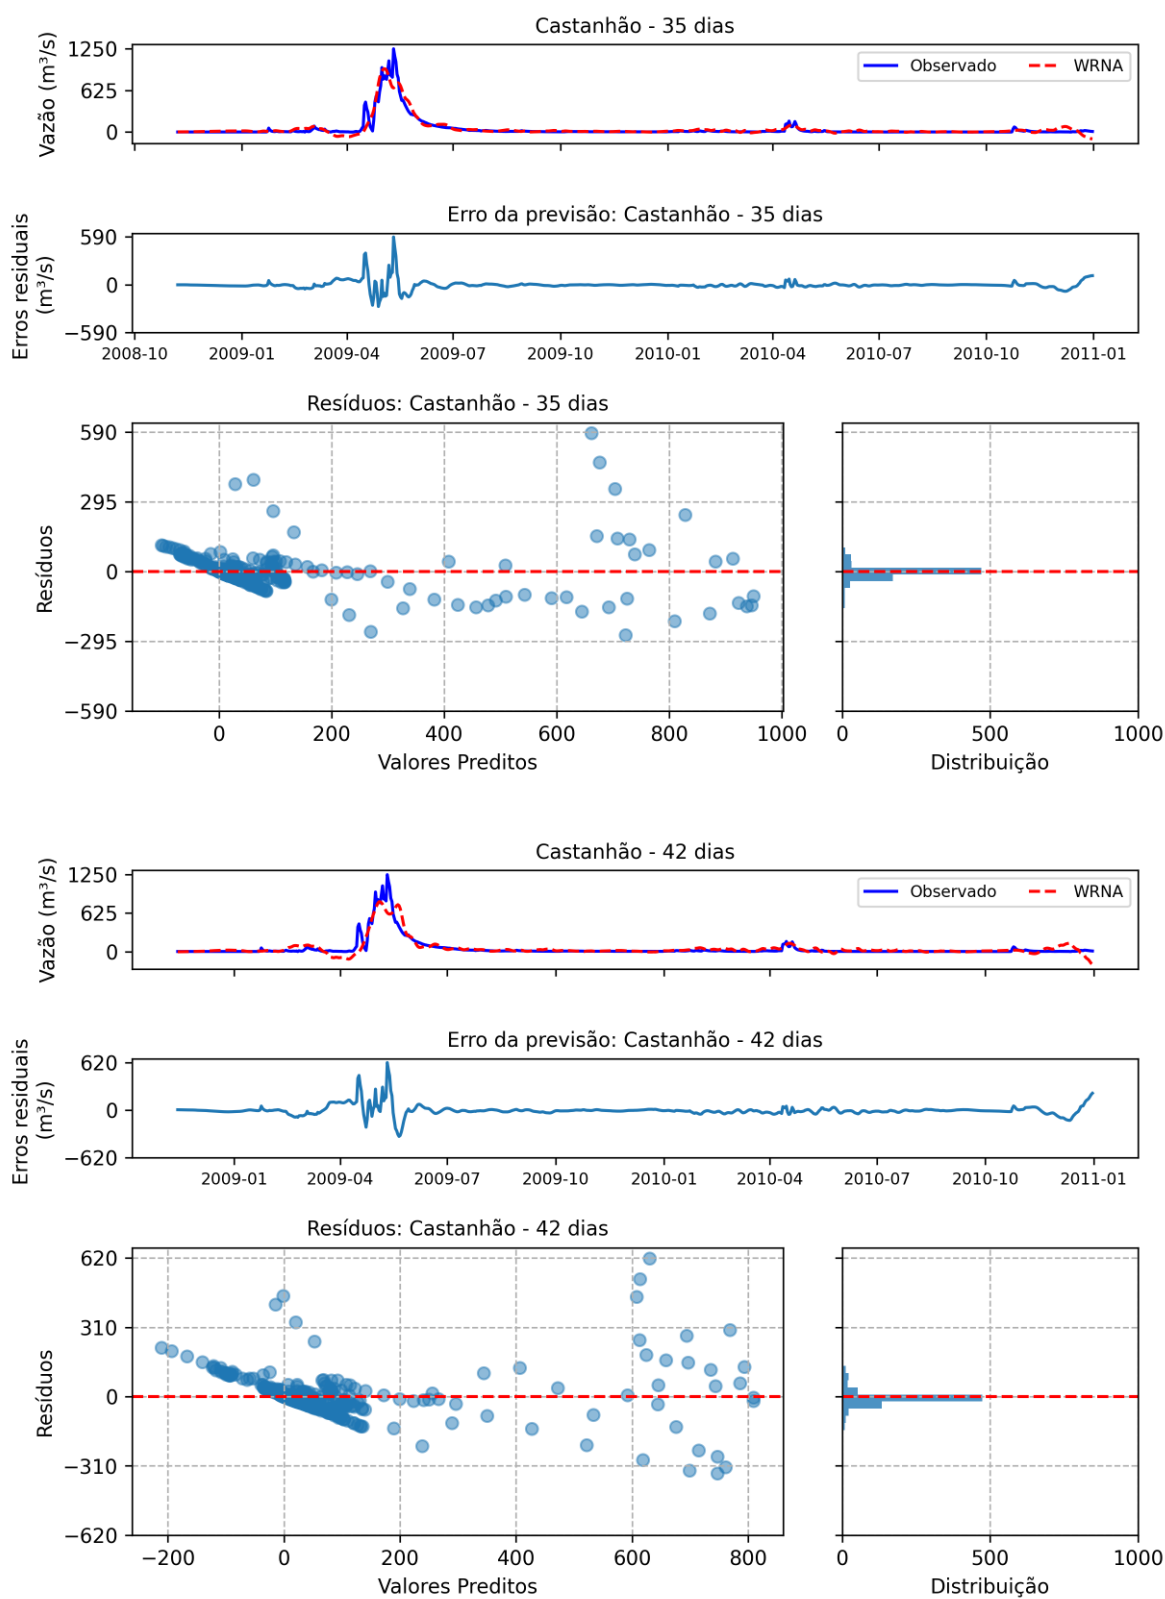
Fonte: Próprio autor

Figura 116 – Previsão WRNA - Xingó 35 e 42 dias



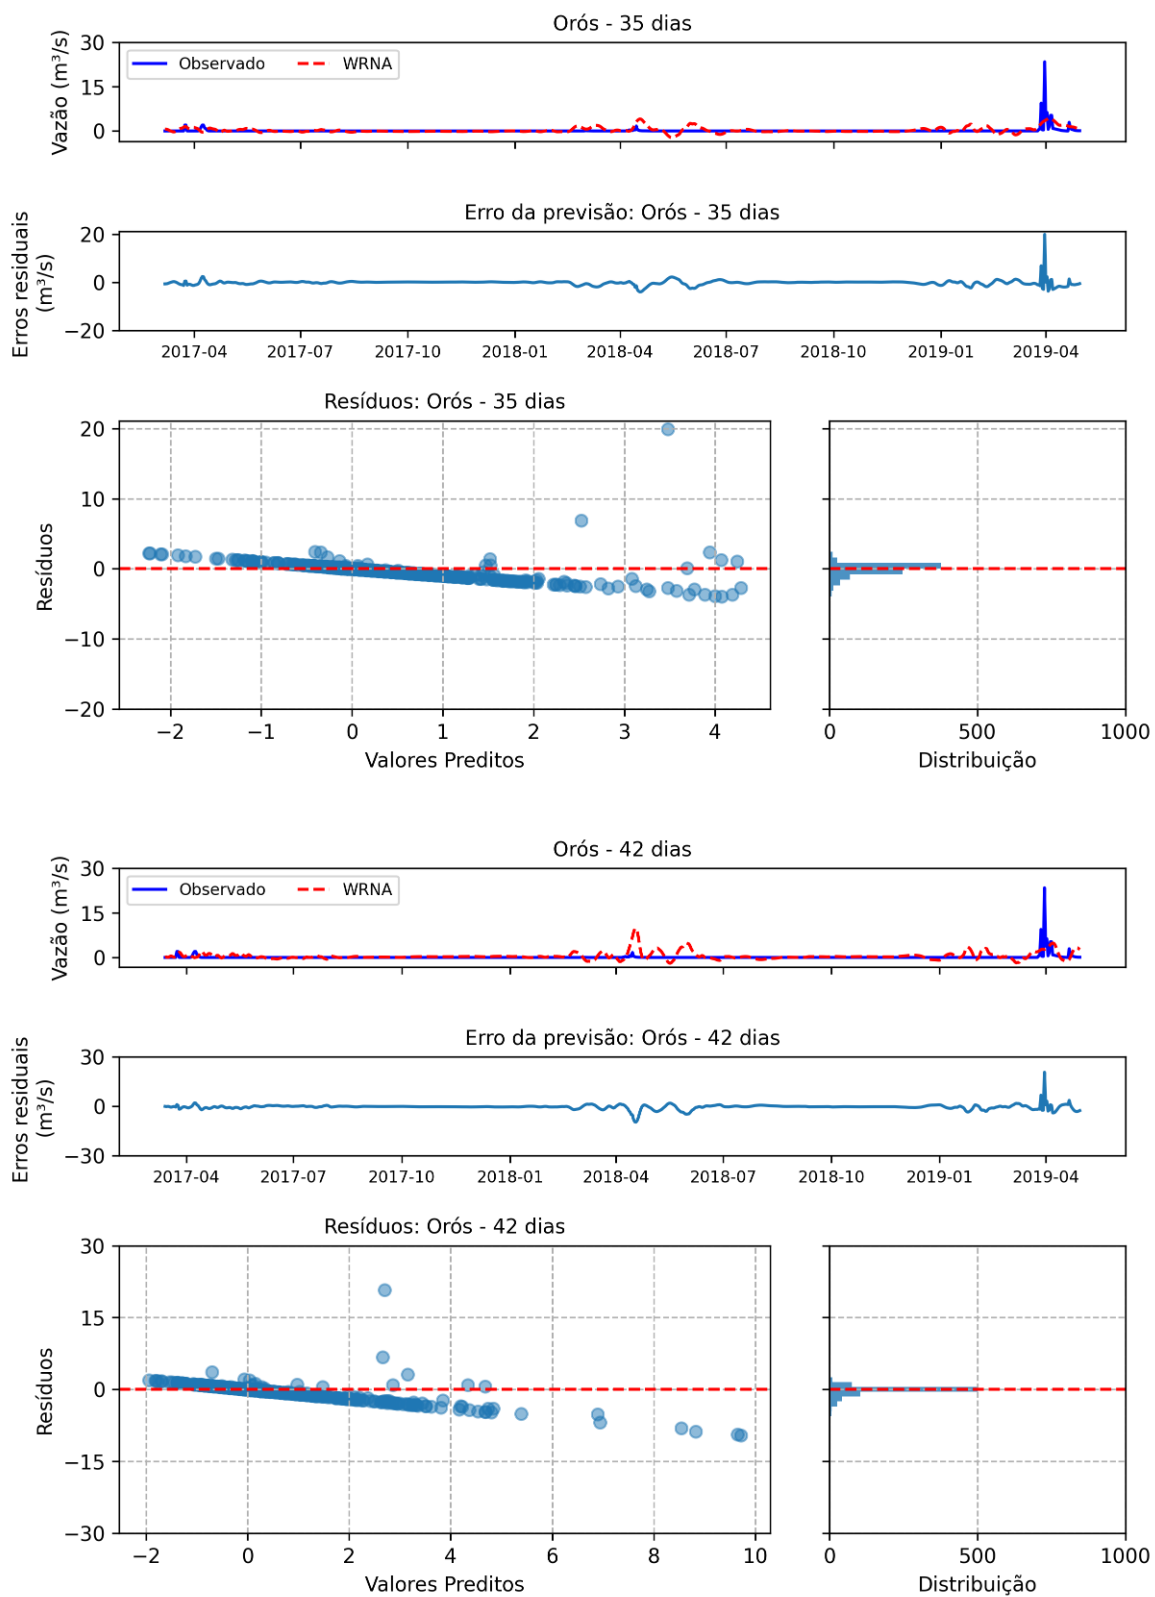
Fonte: Próprio autor

Figura 117 – Previsão WRNA - Castanhão 35 e 42 dias



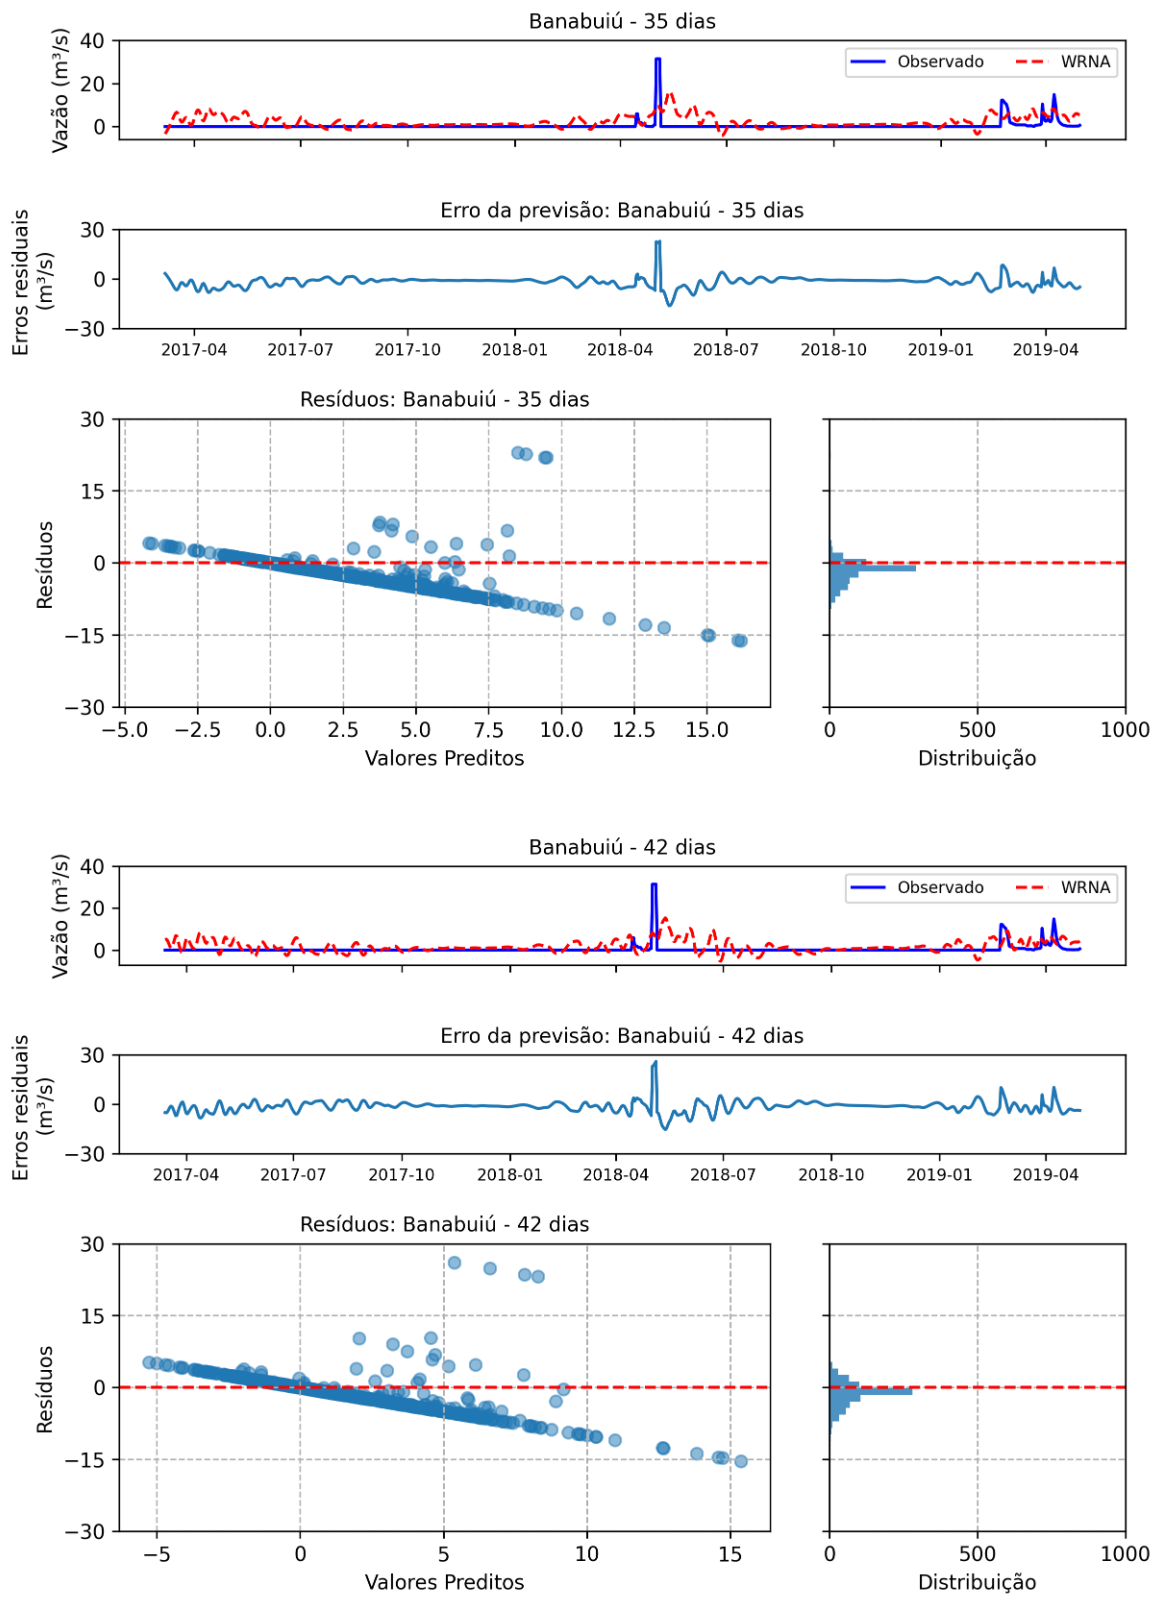
Fonte: Próprio autor

Figura 118 – Previsão WRNA - Orós 35 e 42 dias



Fonte: Próprio autor

Figura 119 – Previsão WRNA - Banabuiú 35 e 42 dias



Fonte: Próprio autor

Tabela 24 – Previsões (WRNA) - Orós

Previsão	Índices	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	nan	nan	0.924	0.631	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-158.455	-2.465	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.521	0.571	1.136	1.177	0.239	0.256	0.164	0.176	0.113	0.102	0.388	0.511
14 dias	r	nan	nan	0.838	0.326	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-248.089	-2.954	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.732	0.771	1.419	1.257	0.614	0.58	0.212	0.107	0.026	0.034	0.125	0.78
21 dias	r	nan	nan	0.832	0.211	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-219.332	-5.446	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.723	1.055	1.335	1.605	0.714	0.792	0.274	0.184	0.129	0.139	0.189	0.466
28 dias	r	nan	nan	0.77	0.083	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-216.055	-7.551	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.473	0.842	1.325	1.848	0.799	0.766	0.272	0.138	0.074	0.077	0.103	0.509
35 dias	r	nan	nan	0.704	0.154	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-105.839	-6.438	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.766	0.844	1.056	1.724	0.901	0.76	0.251	0.184	0.107	0.127	0.142	0.31
42 dias	r	nan	nan	0.576	0.145	nan	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-inf	-131.625	-15.478	-inf	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.15	1.099	1.219	2.566	1.657	0.733	0.318	0.266	0.161	0.244	0.271	0.485

Fonte: Elaborado pelo Autor, 2023

Tabela 25 – Previsões (WRNA) - Banabuiú

Previsão	Índices	Jan	Feb	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
7 dias	r	nan	0.267	0.119	0.816	0.956	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-5.459	-2.719	-4.392	0.856	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.85	4.24	2.569	2.75	3.743	0.992	1.281	0.618	0.31	0.224	0.676	1.744
14 dias	r	nan	0.677	0.497	0.51	0.866	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-0.309	-2.039	-3.235	0.477	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	0.974	1.985	2.322	2.437	7.137	0.987	0.858	0.879	0.344	0.078	0.149	0.733
21 dias	r	nan	0.465	0.512	0.283	0.38	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-2.091	-3.319	-9.278	0.118	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	2.373	3.183	2.769	3.796	9.273	1.355	1.012	0.852	0.288	0.437	0.529	1.114
28 dias	r	nan	0.716	0.578	0.384	0.293	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-1.599	-4.892	-18.782	0.085	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.337	3.058	3.234	5.267	9.444	3.1	1.521	1.088	0.472	0.207	0.168	0.747
35 dias	r	nan	0.257	0.471	-0.014	0.258	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-0.228	-0.399	-12.855	-0.005	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.823	4.486	3.259	4.408	9.899	3.775	1.823	1.352	0.63	0.716	0.888	1.162
42 dias	r	nan	0.101	0.406	-0.007	0.101	nan	nan	nan	nan	nan	nan	nan
	NASH	-inf	-0.403	-0.17	-12.196	-0.137	-inf	-inf	-inf	-inf	-inf	-inf	-inf
	RMSE	1.946	4.796	3.083	4.302	10.527	3.027	2.831	2.298	0.93	0.668	1.035	1.23

Fonte: Elaborado pelo Autor, 2023