

UNIVERSIDADE FEDERAL DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO,
MEIO AMBIENTE E RECURSOS HÍDRICOS

**DESENVOLVIMENTO DE UM SISTEMA
SIMPLIFICADO PARA PREVISÕES
PROBABILÍSTICAS DE AFLUÊNCIAS
AO RESERVATÓRIO DA UHE ITAIPU**

Mariana Maria Werlang

Belo Horizonte

2021

**DESENVOLVIMENTO DE UM SISTEMA
SIMPLIFICADO PARA PREVISÕES
PROBABILÍSTICAS DE AFLUÊNCIAS
AO RESERVATÓRIO DA UHE ITAIPU**

Mariana Maria Werlang

Mariana Maria Werlang

**DESENVOLVIMENTO DE UM SISTEMA
SIMPLIFICADO PARA PREVISÕES
PROBABILÍSTICAS DE AFLUÊNCIAS
AO RESERVATÓRIO DA UHE ITAIPU**

Dissertação apresentada ao Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Saneamento, Meio Ambiente e Recursos Hídricos.

Área de concentração: Recursos Hídricos

Linha de pesquisa: Modelagem de Processos Hidrológicos

Orientador: Wilson dos Santos Fernandes

Coorientador: Francisco Eustáquio Oliveira e Silva

Belo Horizonte

Escola de Engenharia da UFMG

2021

W489d Werlang, Mariana Maria.
Desenvolvimento de um sistema simplificado para previsões probabilísticas de afluências ao reservatório da UHE Itaipu [recurso eletrônico] / Mariana Maria Werlang. – 2021.
1 recurso online (xix, 194 f. : il., color.) : pdf.

Orientador: Wilson dos Santos Fernandes.
Coorientador; Francisco Eustáquio Oliveira e Silva.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 150-194.

Bibliografia: f. 140-149.
Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia sanitária - Teses. 2. Recursos hídricos - Desenvolvimento - Teses. 3. Incerteza - Teses. 4. Previsão - Teses. 5. Probabilidade - Teses. 6. Reservatórios - Teses. I. Fernandes, Wilson dos Santos. II. Silva, Francisco Eustáquio Oliveira e. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 628(043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
COLEGIADO DO CURSO PÓS-GRADUAÇÃO EM SANEAMENTO, MEIO AMBIENTE E RECURSOS HÍDRICOS

FOLHA DE APROVAÇÃO

Desenvolvimento de um sistema simplificado para previsões probabilísticas de aflúências ao reservatório da UHE Itaipu

MARIANA MARIA WERLANG

Dissertação de Mestrado defendida e aprovada, no dia 07 de maio de 2021, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

Prof. Dr. Fernando Mainardi Fan

Membro Externo - UFRGS

Prof. Dr. Eber José de Andrade Pinto

Membro Interno - UFMG

Prof. Dr. Francisco Eustáquio Oliveira e Silva

Coorientador - UFMG

Prof. Dr. Wilson dos Santos Fernandes

Orientador - UFMG

APROVADA PELO COLEGIADO DO PPG SMARH

Sonaly Cristina Rezende Borges de Lima - Coordenadora

Belo Horizonte, 07 de

maio de 2021.



Documento assinado eletronicamente por **Wilson dos Santos Fernandes, Servidor(a)**, em 12/11/2021, às 13:56, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Francisco Eustaquio Oliveira e Silva, Professor do Magistério Superior**, em 12/11/2021, às 16:22, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eber Jose de Andrade Pinto, Professor do Magistério Superior**, em 12/11/2021, às 18:40, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fernando Mainardi Fan, Usuário Externo**, em 16/11/2021, às 13:41, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Sonaly Cristina Rezende Borges de Lima, Coordenador(a) de curso de pós-graduação**, em 18/11/2021, às 13:59, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1078048** e o código CRC **E479E1A5**.

AGRADECIMENTOS

É com grande satisfação que concluo mais esta etapa de minha vida. Foi uma longa e árdua jornada até aqui, iniciada em 2015, interrompida em 2016 e retomada em 2019, e que agora se materializa na forma desta Dissertação.

Durante esse tempo, muitos estiveram ao meu lado, apoiando-me e motivando-me para tal realização. Deixo aqui os meus mais sinceros agradecimentos aos que, direta ou indiretamente, contribuíram para o desenvolvimento desta pesquisa.

Agradeço à ITAIPU Binacional, pela oportunidade em dar continuidade ao Mestrado. Especialmente aos engenheiros Rui Jovita e Celso Torino, que não mediram esforços para que isso fosse possível. Agradeço também por todo o apoio dos meus gerentes, engenheiros Rodrigo Pimenta e José Benedito Mota, e pelo suporte logístico da Cristiane Pimenta, do Christian Le Bourlegat e do Elias Alberto.

Ao meu orientador, professor Wilson Fernandes, e meu coorientador, professor Francisco Silva, pelo conhecimento compartilhado, pela paciência e pelas ricas discussões ao longo da pesquisa.

Aos meus queridos colegas e amigos da Divisão de Estudos Hidrológicos e Energéticos, especialmente aos colegas do Setor de Previsões, Giovanni Gomes, Daniel Kazay, José Maria Fariña, José Quevedo, Marcelo Brauer, Roberto Takahashi e Tannia Villanueva, por todo o incentivo e pelo suporte durante minha ausência.

Aos professores, colegas de curso e funcionários do Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos – SMARH.

A minha família, por sempre acreditar em mim. Sobretudo a minha mãe, Waléria, pelo apoio incondicional em todas minhas decisões, e pela eterna motivação na busca pelo conhecimento, nunca me deixando desistir dos meus sonhos.

Aos meus queridos amigos, pelas palavras de carinho e incentivo, e pela compreensão dos meus momentos de ausência.

Por fim, agradeço de maneira especial ao meu companheiro Claudio, por nunca ter soltado a minha mão e sempre se fazer presente. Obrigada por diariamente me alegrar e motivar, mesmo nos momentos mais difíceis dessa caminhada.

RESUMO

A previsão de vazões afluentes a um aproveitamento hidrelétrico é de extrema importância para a operação de seu reservatório, uma vez que permite o planejamento de sua produção conforme a disponibilidade hídrica e desempenha um papel fundamental na gestão da segurança da barragem. Desse modo, uma previsão hidrológica de qualidade é essencial para que se faça um bom planejamento de gestão dos recursos disponíveis, de forma a aproveitá-los de maneira eficiente, com foco na segurança operacional e na produção hidroenergética, associados à responsabilidade ambiental e social. Nesse sentido, tem sido cada vez mais frequente o uso da modelagem hidrológica como uma ferramenta para apoiar a tomada de decisões quanto ao uso e gerenciamento dos recursos hídricos. No entanto, a modelagem hidrológica e as previsões dela obtidas estão sujeitas a vários tipos de incertezas; assim, as estimativas dessas incertezas devem estar associadas às previsões hidrológicas para subsidiar a tomada de decisões, a fim de se quantificar a confiabilidade acerca dessas previsões e permitir que o tomador de decisões tenha a informação de forma completa, para o gerenciamento de riscos e planejamento de controle. Uma forma de se explicitarem essas incertezas é a partir da geração de previsões probabilísticas de vazão, em lugar de previsões determinísticas, permitindo sinalizar os possíveis cenários futuros diante das diversas incertezas associadas a essas previsões. Esse tipo de abordagem já é bastante difundido na Meteorologia e tem evoluído no que se refere às previsões hidrológicas, mas ainda pode ser considerada incipiente no Brasil e em toda a América do Sul, de forma geral. Nesse contexto, o presente trabalho aborda a utilização de previsões hidrológicas probabilísticas de longo prazo (ou sazonais), com incorporação de incertezas, para o planejamento da operação do reservatório da Usina Hidrelétrica de Itaipu. Para tanto, foi desenvolvido um sistema operacional de previsão sazonal de vazões afluentes ao seu reservatório, composto pelo modelo hidrológico SMAP, em sua versão mensal, associado às previsões climáticas por conjunto (ou *ensemble*) elaboradas pelo ECMWF. A esse sistema são incorporadas, além das incertezas associadas às previsões de precipitação, representadas pelo espalhamento do *ensemble*, aquelas relacionadas aos parâmetros e às variáveis de estado do SMAP. Para tanto, o método GLUE foi aplicado, de forma a se estimarem as incertezas associadas ao modelo hidrológico. O sistema desenvolvido se mostrou uma ferramenta potencialmente útil para a previsão probabilística de vazões afluentes à Itaipu, e a amostra de previsões analisadas, apesar de limitada e insuficiente para a generalização dos resultados, indicou os benefícios de uso das previsões probabilísticas em prol daquelas estritamente determinísticas, representadas pela mediana do conjunto de previsões.

Palavras-chave: Previsão Probabilística, Estimação de Incertezas, GLUE, SMAP

ABSTRACT

The inflows forecast to a hydroelectric plant is extremely important for its reservoir operation, since it allows planning its production according to water availability and also plays a fundamental role in dam safety management. Thus, a hydrological quality forecast is essential for a good planning of the available resources management, in order to employ them efficiently, focusing on operational safety and power plant production, associated with environmental and social responsibility. In this sense, hydrological modeling has been increasingly used as a tool to support decision making in the use and management of water resources. However, hydrological modeling and its predictions are subject to several types of uncertainties; thus, estimates of these uncertainties must be associated with hydrological forecasts to support decision making, in order to quantify the reliability of these forecasts and allow the decision maker to have complete information for risk and control management. One way of explaining these uncertainties is through the use of probabilistic forecasts, instead of deterministic ones, allowing to signal possible future scenarios in view of the various uncertainties associated with these forecasts. This type of approach is already widespread in Meteorology and has evolved in hydrological forecasts, but it can still be considered incipient in Brazil and all South America, in general. In this context, this work addresses the use of long-term (or seasonal) probabilistic hydrological forecasts, with the incorporation of uncertainties, for operation planning of the Itaipu Hydroelectric Power Plant reservoir. For this purpose, an operating system for seasonal forecasting of its reservoir inflows was developed, composed of the hydrological model SMAP, in its monthly version, associated with the climate forecasts by ensemble prepared by ECMWF. Besides the uncertainties associated with precipitation forecasts, represented by the spread of the ensemble, this systems also incorporates those related to model parameters and model states. For this purpose, the GLUE method was applied, in order to estimate the uncertainties associated with the hydrological model. The developed system proved to be a potentially useful tool for probabilistic forecasting of Itaipu's inflows, and the forecasts' sample analyzed, although limited and insufficient for generalizing the results, indicated the benefits of using probabilistic forecasts in favor of strictly deterministic ones, represented by the median of the forecasts ensemble.

Keywords: Probabilistic Forecasting, Uncertainty Estimation, GLUE, SMAP

SUMÁRIO

LISTA DE FIGURAS	VI
LISTA DE TABELAS.....	XV
LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS	XVI
1 INTRODUÇÃO.....	1
2 OBJETIVOS.....	4
2.1 OBJETIVO GERAL	4
2.2 OBJETIVOS ESPECÍFICOS.....	4
3 REVISÃO DA LITERATURA.....	5
3.1 PREVISÃO HIDROLÓGICA.....	5
3.1.1 <i>Contextualização</i>	5
3.1.2 <i>Métodos de previsão hidrológica</i>	8
3.1.3 <i>Sistemas de previsão operacionais</i>	9
3.1.4 <i>Verificação de desempenho de previsões hidrológicas</i>	11
3.2 MODELOS HIDROLÓGICOS.....	13
3.2.1 <i>Contextualização histórica</i>	14
3.2.2 <i>Classificação dos modelos hidrológicos</i>	16
3.2.3 <i>O modelo SMAP</i>	18
3.2.4 <i>Assimilação de dados</i>	22
3.3 PREVISÃO DE PRECIPITAÇÃO.....	25
3.3.1 <i>Modelos meteorológicos</i>	25
3.3.2 <i>Evolução das previsões numéricas de tempo</i>	28
3.3.3 <i>Previsão do tempo versus previsão climática</i>	31
3.3.4 <i>Modelos acoplados de circulação geral (CGCMs)</i>	33
3.3.5 <i>Uso das previsões climáticas em aplicações hidrológicas</i>	36
3.4 PREVISÃO HIDROLÓGICA E SUAS INCERTEZAS	38
3.4.1 <i>Incertezas associadas à previsão de precipitação</i>	40
3.4.2 <i>Incertezas associadas à modelagem hidrológica</i>	43
4 MATERIAL E MÉTODOS	51
4.1 ÁREA DE ESTUDO.....	51
4.2 DADOS HIDROMETEOROLÓGICOS	54
4.3 CALIBRAÇÃO DO MODELO HIDROLÓGICO.....	58
4.3.1 <i>Calibração convencional</i>	59
4.3.2 <i>Calibração pelo método GLUE</i>	61
4.4 ATUALIZAÇÃO DAS VARIÁVEIS DE ESTADO.....	63
4.5 PREVISÃO DE VAZÕES E INCORPORAÇÃO DE INCERTEZAS	64
4.5.1 <i>Previsão de precipitação</i>	64
4.5.2 <i>Previsão hidrológica</i>	67
5 RESULTADOS E DISCUSSÃO	69
5.1 CALIBRAÇÃO DO MODELO HIDROLÓGICO.....	69
5.1.1 <i>Calibração convencional</i>	69
5.1.2 <i>Calibração pelo método GLUE</i>	82
5.2 SIMULAÇÕES PONDERADAS.....	90
5.3 PREVISÃO DE VAZÕES E INCORPORAÇÃO DE INCERTEZAS	94
5.3.1 <i>Previsão de afluência à Itaipu</i>	94
5.3.2 <i>Previsão de vazão natural da bacia incremental</i>	107
5.3.3 <i>Previsão de precipitação sobre a bacia incremental</i>	119
6 CONCLUSÕES E RECOMENDAÇÕES	136

REFERÊNCIAS	140
APÊNDICE A: ESP'S OBTIDOS PARA CADA SUB-BACIA MODELADA, PARA AS DIFERENTES SÉRIES DE PRECIPITAÇÃO PREVISTA	150
APÊNDICE B: DESEMPENHO DA MEDIANA DAS PREVISÕES DE CADA SUB-BACIA MODELADA, PARA AS SÉRIES DE PRECIPITAÇÃO PREVISTA.....	187

LISTA DE FIGURAS

Figura 3.1 - Evolução da aplicabilidade das previsões hidrológicas de acordo com a antecedência necessária à tomada de decisões (Fonte: adaptado de NASEM, 2016).	6
Figura 3.2 - Diagramas esquemáticos do modelo SMAP, em suas versões (a) diária, (b) mensal e (c) horária (Fonte: adaptado de Lopes, 1999).	19
Figura 3.3 - Sistema de observação global: instalações de observação em superfície, no mar, no ar e no espaço sideral, pertencentes e operadas pelos países membro da OMM (Fonte: WMO, 2021).	29
Figura 3.4 - Evolução da acurácia das previsões do tempo de horizontes de 3, 5, 7 e 10 dias, para os hemisférios Norte (HN) e Sul (HS) (Fonte: adaptado de Bauer et al., 2015).	30
Figura 3.5 - Impactos climáticos do fenômeno El Niño ao longo do globo terrestre (Fonte: adaptado de NOAA Climate.gov, 2021).	34
Figura 3.6 - Impactos climáticos do fenômeno La Niña ao longo do globo terrestre (Fonte: adaptado de NOAA Climate.gov, 2021).	35
Figura 3.7 – Exemplo ilustrativo de previsão hidrológica probabilística (Fonte: NWS/NOAA, 2021a).	39
Figura 3.8 - Representação de uma previsão por <i>ensemble</i> obtida a partir de perturbações nas condições de inicialização do modelo meteorológico (Fonte: adaptado de Fan, 2015).	41
Figura 3.9 - Exemplo ilustrativo de um ESP para um evento de inundação	42
Figura 3.10 - Incertezas associadas à modelagem hidrológica (Fonte: adaptado de Vrugt e Massoud, 2019).	43
Figura 3.11 - Esquema representativo da simulação de Monte Carlo para análise de incertezas (Fonte: adaptado de Silva, 2015).	47
Figura 3.12 - Esquema representativo das etapas da metodologia GLUE (Fonte: adaptado de Jensen, 2003).	49
Figura 4.1 - Bacia incremental da UHE Itaipu, delimitada a montante pelas usinas de Porto Primavera e de Rosana.	51
Figura 4.2 - Normais climatológicas das precipitação média mensais, com destaque para a bacia incremental de Itaipu (Fonte: CRC-SAS, 2021).	54
Figura 4.3 - Disposição espacial dos postos fluviométricos e pluviométricos utilizados para a calibração do SMAP.	56
Figura 4.4 - Disposição espacial das estações meteorológicas do INMET, cujas normais climatológicas foram utilizadas no cálculo da ETP média de cada sub-bacia.	58
Figura 4.5 - Serviços de informação temática do Programa Copernicus (Fonte: COPERNICUS, 2021).	64
Figura 4.6 - Anomalia de Temperatura da Superfície do Mar na região Niño 3.4 do Oceano Pacífico Central e destaque para o período analisado (Fonte dos dados: CPC/NOAA, 2021).	66
Figura 4.7 - Pontes de grade inseridos na área de estudo.	66
Figura 5.1 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Piquiri.	70
Figura 5.2 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Ivaí.	70
Figura 5.3 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Ivinhema.	71
Figura 5.4 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Amambáí.	71
Figura 5.5 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Iguatemi.	72

Figura 5.6 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia “não-monitorada”.	72
Figura 5.7 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Piquiri.	73
Figura 5.8 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Ivaí.	73
Figura 5.9 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Ivinhema.	74
Figura 5.10 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Amambaí.	74
Figura 5.11 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Iguatemi.	75
Figura 5.12 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia “não-monitorada”.	75
Figura 5.13 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Piquiri.	76
Figura 5.14 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Ivaí.	77
Figura 5.15 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Ivinhema.	77
Figura 5.16 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Amambaí.	77
Figura 5.17 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Iguatemi.	78
Figura 5.18 - Evolução temporal do erro relativo da simulação, para a sub-bacia “não-monitorada”.	78
Figura 5.19 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Piquiri.	79
Figura 5.20 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Ivaí.	79
Figura 5.21 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Ivinhema.	80
Figura 5.22 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Amambaí.	80
Figura 5.23 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Iguatemi.	81
Figura 5.24 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia “não-monitorada”.	81
Figura 5.25 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Piquiri.	83
Figura 5.26 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Ivaí.	84
Figura 5.27 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Ivinhema.	84

Figura 5.28 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Amambaí. ...	85
Figura 5.29 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Iguatemi.....	85
Figura 5.30 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia “não-monitorada”. ...	86
Figura 5.31 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Piquiri.....	87
Figura 5.32 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Ivaí.	88
Figura 5.33 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Ivinhema.....	88
Figura 5.34 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Amambaí.....	89
Figura 5.35 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Iguatemi.	89
Figura 5.36 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia “não-monitorada”.	90
Figura 5.37 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Piquiri.....	91
Figura 5.38 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Ivaí.	92
Figura 5.39 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Ivinhema.	92
Figura 5.40 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Amambaí.....	93
Figura 5.41 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Iguatemi.	93
Figura 5.42 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia “não-monitorada”.	94
Figura 5.43 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em agosto/2018.	95
Figura 5.44 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em setembro/2018.....	95
Figura 5.45 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em outubro/2018.	96
Figura 5.46 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em novembro/2018.	96
Figura 5.47 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em dezembro/2018.....	96
Figura 5.48 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em janeiro/2019.....	97
Figura 5.49 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em fevereiro/2019.	97
Figura 5.50 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em março/2019.....	97
Figura 5.51 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em abril/2019.	98
Figura 5.52 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em maio/2019.....	98

Figura 5.53 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em junho/2019.....	98
Figura 5.54 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em julho/2019.	99
Figura 5.55 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas de aflúência à Itaipu para todo o horizonte previsto, para cada mês de início da previsão.....	100
Figura 5.56 - Desempenho geral da mediana das previsões probabilísticas de aflúência à Itaipu, para cada horizonte do mês previsto.	101
Figura 5.57 - Evolução do desempenho da mediana de cada série de previsão probabilística de aflúência à Itaipu, mês a mês.....	101
Figura 5.58 - Evolução do BS das previsões probabilísticas de aflúência à Itaipu, para cada horizonte do mês previsto.....	103
Figura 5.59 - Evolução do BSS das previsões probabilísticas de aflúência à Itaipu em relação à mediana das previsões, para cada horizonte do mês previsto.....	104
Figura 5.60 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de aflúência à Itaipu (linha 1:1 para referência).	106
Figura 5.61 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em agosto/2018.....	107
Figura 5.62 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em setembro/2018.....	108
Figura 5.63 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em outubro/2018.....	108
Figura 5.64 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em novembro/2018. ...	108
Figura 5.65 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em dezembro/2018. ...	109
Figura 5.66 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em janeiro/2019.	109
Figura 5.67 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em fevereiro/2019.....	109
Figura 5.68 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em março/2019.	110
Figura 5.69 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em abril/2019.....	110
Figura 5.70 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em maio/2019.	110
Figura 5.71 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em junho/2019.	111
Figura 5.72 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em julho/2019.	111
Figura 5.73 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da vazão incremental para todo o horizonte previsto, para cada mês de início da previsão.	112
Figura 5.74 - Desempenho geral da mediana das previsões probabilísticas da vazão incremental, para cada horizonte do mês previsto.	113
Figura 5.75 - Evolução do desempenho da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.	113
Figura 5.76 - Evolução do BS das previsões probabilísticas de vazão incremental à Itaipu, para cada horizonte do mês previsto.	115
Figura 5.77 - Evolução do BSS das previsões probabilísticas de vazão incremental à Itaipu em relação à mediana das previsões, para cada horizonte do mês previsto.	116

Figura 5.78 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de vazão incremental à Itaipu (linha 1:1 para referência).	118
Figura 5.79 - Mapas de anomalias das precipitações média mensais dos meses avaliados nas previsões hidrológicas, com destaque para a bacia incremental de Itaipu (Fonte: INMET, 2021).	122
Figura 5.80 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em agosto/2018.	123
Figura 5.81 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em setembro/2018.	124
Figura 5.82 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em outubro/2018.	124
Figura 5.83 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em novembro/2018.	124
Figura 5.84 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em dezembro/2018.	125
Figura 5.85 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em janeiro/2019.	125
Figura 5.86 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em fevereiro/2019.	125
Figura 5.87 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em março/2019.	126
Figura 5.88 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em abril/2019.	126
Figura 5.89 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em maio/2019.	126
Figura 5.90 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em junho/2019.	127
Figura 5.91 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em julho/2019.	127
Figura 5.92 - Desempenho global (MAE e MRE) da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, para cada mês de início da previsão.	128
Figura 5.93 - Desempenho geral da mediana da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, para cada horizonte do mês previsto.	129
Figura 5.94 - Evolução do desempenho da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.	129
Figura 5.95 - Evolução do BS das previsões probabilísticas precipitação sobre a bacia incremental, para cada horizonte do mês previsto.	132
Figura 5.96 - Evolução do BSS das previsões probabilísticas de precipitação sobre a bacia incremental para cada horizonte do mês previsto, em relação (A) à mediana das previsões, (B) à climatologia.	132
Figura 5.97 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de vazão incremental à Itaipu (linha 1:1 para referência).	134
Figura AP.1 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em agosto/2018.	151
Figura AP.2 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em agosto/2018.	151
Figura AP.3 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em agosto/2018.	152
Figura AP.4 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em agosto/2018.	152

Figura AP.5 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em agosto/2018.	153
Figura AP.6 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em agosto/2018.....	153
Figura AP.7 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em setembro/2018.	154
Figura AP.8 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em setembro/2018.	154
Figura AP.9 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em setembro/2018.	155
Figura AP.10 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em setembro/2018.....	155
Figura AP.11 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em setembro/2018.	156
Figura AP.12 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em setembro/2018.	156
Figura AP.13 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em outubro/2018.....	157
Figura AP.14 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em outubro/2018.	157
Figura AP.15 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em outubro/2018.	158
Figura AP.16 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em outubro/2018.....	158
Figura AP.17 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em outubro/2018.	159
Figura AP.18 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em outubro/2018.....	159
Figura AP.19 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em novembro/2018.....	160
Figura AP.20 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em novembro/2018.....	160
Figura AP.21 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em novembro/2018.....	161
Figura AP.22 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em novembro/2018.....	161
Figura AP.23 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em novembro/2018.....	162
Figura AP.24 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em novembro/2018.....	162
Figura AP.25 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em dezembro/2018.	163
Figura AP.26 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em dezembro/2018.....	163
Figura AP.27 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em dezembro/2018.	164
Figura AP.28 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em dezembro/2018.	164
Figura AP.29 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em dezembro/2018.....	165

Figura AP.30 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em dezembro/2018.	165
Figura AP.31 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em janeiro/2019.	166
Figura AP.32 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em janeiro/2019.	166
Figura AP.33 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em janeiro/2019.	167
Figura AP.34 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em janeiro/2019.	167
Figura AP.35 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em janeiro/2019.	168
Figura AP.36 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em janeiro/2019.	168
Figura AP.37 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em fevereiro/2019.	169
Figura AP.38 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em fevereiro/2019.	169
Figura AP.39 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em fevereiro/2019.	170
Figura AP.40 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em fevereiro/2019.	170
Figura AP.41 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em fevereiro/2019.	171
Figura AP.42 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em fevereiro/2019.	171
Figura AP.43 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em março/2019.	172
Figura AP.44 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em março/2019.	172
Figura AP.45 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em março/2019.	173
Figura AP.46 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em março/2019.	173
Figura AP.47 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em março/2019.	174
Figura AP.48 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em março/2019.	174
Figura AP.49 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em abril/2019.	175
Figura AP.50 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em abril/2019.	175
Figura AP.51 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em abril/2019.	176
Figura AP.52 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em abril/2019.	176
Figura AP.53 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em abril/2019.	177
Figura AP.54 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em abril/2019.	177

Figura AP.55 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em maio/2019.....	178
Figura AP.56 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em maio/2019.....	178
Figura AP.57 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em maio/2019.....	179
Figura AP.58 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em maio/2019.....	179
Figura AP.59 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em maio/2019.....	180
Figura AP.60 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em maio/2019.....	180
Figura AP.61 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em junho/2019.....	181
Figura AP.62 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em junho/2019.....	181
Figura AP.63 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em junho/2019.....	182
Figura AP.64 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em junho/2019.....	182
Figura AP.65 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em junho/2019.....	183
Figura AP.66 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em junho/2019.....	183
Figura AP.67 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em julho/2019.....	184
Figura AP.68 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em julho/2019.....	184
Figura AP.69 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em julho/2019.....	185
Figura AP.70 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em julho/2019.....	185
Figura AP.71 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em julho/2019.....	186
Figura AP.72 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em julho/2019.....	186
Figura AP.73 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Piquiri para todo o horizonte previsto, para cada mês de início da previsão.....	188
Figura AP.74 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Ivaí para todo o horizonte previsto, para cada mês de início da previsão. ...	188
Figura AP.75 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Ivinhema para todo o horizonte previsto, para cada mês de início da previsão.....	188
Figura AP.76 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Amambaí para todo o horizonte previsto, para cada mês de início da previsão.....	189
Figura AP.77 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Iguatemi para todo o horizonte previsto, para cada mês de início da previsão.....	189

Figura AP.78 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia “não-monitorada” para todo o horizonte previsto, para cada mês de início da previsão.....	189
Figura AP.79 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Piquiri, para cada horizonte do mês previsto.....	190
Figura AP.80 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Ivaí, para cada horizonte do mês previsto.	190
Figura AP.81 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Ivinhema, para cada horizonte do mês previsto.	190
Figura AP.82 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Amambaí, para cada horizonte do mês previsto.....	191
Figura AP.83 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Iguatemi, para cada horizonte do mês previsto.	191
Figura AP.84 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia “não-monitorada”, para cada horizonte do mês previsto.....	191
Figura AP.85 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Piquiri, mês a mês.	192
Figura AP.86 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Ivaí, mês a mês.....	192
Figura AP.87 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Ivinhema, mês a mês.....	193
Figura AP.88 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Amambaí, mês a mês.	193
Figura AP.89 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Iguatemi, mês a mês.....	194
Figura AP.90 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia “não-monitorada”, mês a mês.....	194

LISTA DE TABELAS

Tabela 3.1 – Exemplos de demandas de previsões hidrológicas para diferentes escalas espacial e temporal. Fonte: Sene (2010).....	7
Tabela 3.2 – Limites dos parâmetros calibráveis do SMAP, em sua versão mensal. Fonte: Lopes (1999).	20
Tabela 3.3 - Exemplos de técnicas de assimilação de dados em aplicações de previsão hidrológica (Fonte: adaptado de Sene, 2010).	23
Tabela 3.4 - Centros de Produção Global da OMM (Fonte: WMO, 2020).	26
Tabela 4.1 - Postos hidrometeorológicos utilizados na calibração do modelo SMAP.....	55
Tabela 4.2 - Postos hidrometeorológicos utilizados na calibração do modelo SMAP.....	57
Tabela 4.3 - Limites estendidos dos parâmetros calibráveis do SMAP.	61
Tabela 5.1 - Resultados da calibração convencional de cada uma das seis sub-bacias modeladas no SMAP (período de janeiro/2004 a julho/2019).	69
Tabela 5.2 - Resultados da calibração pelo método GLUE para cada sub-bacia modelada....	87
Tabela 5.3 - Métricas globais calculadas a partir das simulações comportamentais ponderadas pelos pesos $w\theta_i$	91
Tabela 5.4 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da defluência à Itaipu para todo o horizonte previsto, para cada mês de início da previsão.....	100
Tabela 5.5 - Desempenho geral da mediana das previsões probabilísticas de defluência à Itaipu, para cada horizonte do mês previsto.	101
Tabela 5.6 - Evolução do erro absoluto médio (MAE) da mediana de cada série de previsão probabilística de defluência à Itaipu, mês a mês.	102
Tabela 5.7 - Evolução do erro relativo médio (MRE) da mediana de cada série de previsão probabilística de defluência à Itaipu, mês a mês.	102
Tabela 5.8 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da vazão incremental para todo o horizonte previsto, para cada mês de início da previsão.	112
Tabela 5.9 - Desempenho geral da mediana das previsões probabilísticas da vazão incremental, para cada horizonte do mês previsto.	113
Tabela 5.10 - Evolução do erro absoluto médio (MAE) da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.....	114
Tabela 5.11 - Evolução do erro relativo médio (MRE) da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.....	114
Tabela 5.12 - Desempenho global (MAE e MRE) da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, para cada mês de início da previsão....	128
Tabela 5.13 - Desempenho geral da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, para cada horizonte do mês previsto.	129
Tabela 5.14 - Evolução do erro absoluto médio (MAE) da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.	130
Tabela 5.15 - Evolução do erro relativo médio (MRE) da mediana do <i>ensemble</i> de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.	130

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

AD: área de drenagem

ANA: Agência Nacional de Águas e Saneamento Básico

ARIMA: Modelo Autorregressivo de Média Móvel

BD: banco de dados

BMA: *Bayesian Model Averaging*

BNM: sub-bacia “não-monitorada”

BS: *Brier Score*

BSM: sub-bacia delimitada pela estação hidrométrica Balsa Santa Maria

BSS: *Brier Skill Score*

CAPC: capacidade de campo

C3S: *Copernicus Climate Change Service*

CDS: *Climate Data Store*

CFS: *Climate Forecast System*

CGCM: *Coupled atmosphere-ocean-land General Circulation Model*

CMCC: *Centro Euro-Mediterraneo sui Cambiamenti Climatici*

CPC: *Climate Prediction Center*

CPTEC: Centro de Previsão do Tempo e Estudos Climáticos

CREC: coeficiente de recarga

CRPS Médio: *Mean Continuous Ranked Probability Score*

DDS: *Dynamically Dimensioned Search*

DEMETER: *Development of a European Multimodel Ensemble system for seasonal to inTERannual prediction*

Diagrama ROC: *Relative Operating Characteristic Diagram*

DWD: *Deutscher Wetterdienst*

E2: parâmetro de escoamento superficial

Eb: escoamento básico

ECMWF: *European Centre for Medium-Range Weather Forecasts*

EFAS: *European Flood Awareness System*

EHR: Departamento de Engenharia Hidráulica e Recursos Hídricos

ENIAC: *Electronic Numerical Integrator and Computer*

ENSO: *El Niño Southern Oscillation*

Ep: evapotranspiração potencial

Er: evapotranspiração real

Es: escoamento superficial

ESP: *Ensemble Streamflow Prediction*

ETP: Evapotranspiração Potencial

FDP: Função Densidade de Probabilidade

FLO: sub-bacia delimitada pela estação hidrométrica Flórida

FLU: posto fluviométrico

GLUE: *Generalized Likelihood Uncertainty Estimation*

GPC: *Global Producing Centre*

GRIB: *General Regularly-distributed Information in Binary Form*

HEPEX: *The Hydrologic Ensemble Prediction Experiment*

H-ESP: *Hydrologic Ensemble Prediction System*

IAHS: *International Association of Hydrological Sciences*

IGT: sub-bacia delimitada pela estação hidrométrica Estrada do Iguatemi

INC: bacia incremental de Itaipu

INMET: Instituto Nacional de Meteorologia

INPE: Instituto Nacional de Pesquisas Espaciais

IOD: *Indian Ocean Dipole*

IVI: sub-bacia delimitada pela estação hidrométrica Porto Ivinhema

JMA: *Japanese Meteorological Agency*

K: constante de recessão do reservatório do solo

MAE: *Mean Absolute Error*

MC: Monte Carlo

MME: *Multi-Model Ensemble*

MRE: *Mean Relative Error*

NAO: *North Atlantic Oscillation*

NASA: *National Aeronautics and Space Administration*

NCAR: *National Center for Atmospheric Research*
NCEP: *National Centers for Environmental Prediction*
NMME: *North American Multimodel Ensemble*
NOAA: *U.S. National Oceanic and Atmospheric Administration*
NPT: sub-bacia delimitada pela estação hidrométrica Novo Porto Taquara
NSE: *Nash-Sutcliffe Efficiency*
NWP: *Numerical Weather Predictions*
NWS: *U.S. National Weather Service*
OMM: *Organização Meteorológica Mundial*
ONS: *Operador Nacional do Sistema*
P: precipitação
PDO: *Pacific Decadal Oscillation*
PLU: posto pluviométrico
QO: vazão observada
QPF: *Quantitative Precipitation Forecast*
QS: vazão simulada
Rc: reservatório de canal
Rec: recarga subterrânea
RFC: *River Forecast Centers*
RMSE: *Root Mean Square Error*
Rsolo: reservatório de solo
Rsub: reservatório subterrâneo
Rsup: reservatório de superfície
S2S: *Sub-Seasonal to Seasonal Prediction Project*
SAT: capacidade de saturação do solo
SCS: *Soil Conservation Service*
SEAS: *Seasonal Forecast System*
SIN: Sistema Interligado Nacional
SISDAGRO: Sistema de Suporte à Decisão na Agropecuária
SLS: *Standard Least Squares*

SMAP: *Soil Moisture Accounting Procedure*

SOLIN: umidade inicial do solo

SUBIN: vazão de base inicial

t: instante de tempo

TSM: Temperatura da Superfície do Mar

TU: taxa de umidade do solo

UFMG: Universidade Federal de Minas Gerais

UHE: Usina Hidrelétrica

UL: limite de incerteza

UTC/GMT: *Coordinated Universal Time / Greenwich Mean Time*

VBA: *Visual Basic for Applications*

1 INTRODUÇÃO

O sistema elétrico brasileiro, ou Sistema Interligado Nacional (SIN), é um sistema hidro-termo-eólico de grande porte, no qual predomina a geração hidráulica a partir das usinas hidrelétricas (UHEs). Tais usinas respondem atualmente por cerca de 65% da geração elétrica no país (EPE, 2020) e são operadas de forma centralizada pelo Operador Nacional do Sistema (ONS). A centralização dessa operação tem por objetivo promover a otimização da operação do sistema elétrico, visando ao menor custo para o sistema e à garantia da segurança do suprimento energético contínuo em todo o país (ONS, 2020c).

Devido a essa característica, a geração elétrica no país e a precificação da energia gerada são fortemente dependentes das condições hidrológicas vigentes e futuras. Nesse sentido, a antecipação das condições hidrológicas se mostra fundamental, uma vez que auxilia nas decisões e estratégias de produção e de armazenamento de energia nas usinas hidrelétricas. Assim, busca-se otimizar ou maximizar a produção das UHEs conforme a disponibilidade hídrica e reduzir os custos de complementação térmica de geração (BRIANEZI, 2015; FAYAL, 2008).

Isso posto, infere-se que uma previsão hidrológica de qualidade é essencial para que se faça um bom planejamento de gestão dos recursos disponíveis, não só no que se refere ao atendimento da demanda energética, como também nos usos múltiplos da água, na segurança operacional e no controle de cheias. Nesse sentido, o uso da modelagem hidrológica como ferramenta para previsão de vazões tem sido cada vez mais frequente, apoiando a tomada de decisões quanto ao uso e ao gerenciamento dos recursos hídricos, principalmente no que se refere à operação de reservatórios e ao controle de cheias, associados à responsabilidade ambiental e social.

Em geral, a principal forma de se obterem vazões futuras com antecedências superiores ao tempo de concentração da bacia hidrográfica modelada é utilizando-se previsões de precipitação como forçantes do modelo hidrológico (FAN, 2015). Tais antecedências podem ser de curto, médio e longo prazo, a depender do horizonte da previsão meteorológica utilizada. As previsões hidrológicas de longo prazo, foco deste trabalho, utilizam previsões climáticas (ou sazonais) de precipitação, de horizontes previstos superiores a um mês, e têm se mostrado de grande importância no apoio ao planejamento do uso do recurso hídrico e ao gerenciamento de riscos em empreendimentos hidrelétricos (SILVA et al., 2006).

Apesar de ser extensivamente utilizada na tomada de decisões, a modelagem hidrológica e as previsões obtidas a partir dela estão sujeitas a vários tipos de incertezas, as quais muitas vezes não são levadas em consideração no gerenciamento de riscos. Essas incertezas podem ser resumidas quanto às suas fontes em: (i) aleatoriedade inerente aos processos hidrometeorológicos; (ii) dados de entrada (forçantes) ao modelo; (iii) estrutura do modelo e sua incapacidade de representar exatamente o real comportamento do sistema; e (iv) parâmetros do modelo (KRZYSZTOFOWICZ, 2001; MONTANARI, 2011; NETO, 2013; XAVIER, 2002). Dessa forma, as estimativas dessas incertezas devem estar associadas às previsões hidrológicas para subsidiar a tomada de decisões, a fim de se quantificar a confiabilidade das saídas resultantes dos modelos hidrológicos e permitir que o tomador de decisões possa ter a informação de forma completa para o gerenciamento de riscos e planejamento de controle (ZHANG et al., 2020).

Uma forma de se explicitarem essas incertezas é a partir da geração de previsões probabilísticas de vazão, em lugar das previsões determinísticas. Desse modo, é possível sinalizar os possíveis cenários futuros diante das diversas incertezas associadas às previsões hidrológicas. Esse tipo de abordagem já é bastante difundido na Meteorologia e tem evoluído no que se refere às previsões hidrológicas, tal como apresentado nos trabalhos de Fan (2015) e Cloke e Pappenberger (2009), mas ainda pode ser considerada incipiente no Brasil e em toda a América do Sul, de uma forma geral (FAN, 2015).

Nesse contexto, a presente dissertação aborda a utilização de previsões hidrológicas probabilísticas de longo prazo no planejamento da operação do reservatório da Usina Hidrelétrica de Itaipu, localizada na bacia hidrográfica do rio Paraná. Por se tratar de uma usina hidrelétrica a fio de água, a previsão hidrológica de longo prazo é de grande importância para apoiar o planejamento do uso do recurso hídrico e o gerenciamento de riscos da usina, e a incorporação das incertezas associadas a essa previsão é essencial para proporcionar uma visão mais ampla dos possíveis cenários futuros, subsidiando assim a tomada de decisões.

Desse modo, foi desenvolvido um sistema operacional simplificado para a previsão sazonal de vazões afluentes ao seu reservatório, composto pelo modelo hidrológico SMAP (*Soil Moisture Accounting Procedure*), em sua versão mensal, associado às previsões climáticas elaboradas pelo ECMWF (*European Centre for Medium-Range Weather Forecasts*).

A esse sistema são incorporadas, além das incertezas acerca das previsões de precipitação, representadas pelo espalhamento do *ensemble*, aquelas associadas aos parâmetros e às variáveis de estado do modelo hidrológico. Para tanto, o método GLUE (*Generalized Likelihood Uncertainty Estimation*) foi aplicado, de forma a se estimarem as incertezas relacionadas ao modelo hidrológico utilizado.

O desenvolvimento desse sistema se justifica como uma possível ferramenta para a previsão de longo prazo das afluências mensais ao reservatório da UHE Itaipu, com suas respectivas incertezas associadas, a fim de se planejar sua operação frente aos possíveis cenários hidrológicos futuros.

2 OBJETIVOS

2.1 *Objetivo geral*

Este trabalho tem como objetivo desenvolver um sistema simplificado de previsão sazonal de vazões afluentes ao reservatório da UHE Itaipu, com discretização mensal, composto por um modelo hidrológico do tipo chuva-vazão alimentado por previsões de precipitação por conjunto. Além das incertezas inerentes às previsões meteorológicas, serão também incorporadas as incertezas associadas aos parâmetros e às variáveis de estado que compõem o modelo hidrológico.

2.2 *Objetivos específicos*

- Utilizar o método GLUE para estimação das incertezas paramétricas e preditivas do modelo hidrológico SMAP;
- Desenvolver um procedimento de assimilação de dados, por meio da atualização das variáveis de estado do modelo hidrológico no instante imediatamente anterior ao da simulação de vazões futuras, a fim de se reduzirem as incertezas iniciais dessas previsões;
- Obter vazões futuras a partir de cada um dos conjuntos de parâmetros elegidos pelo método GLUE, ponderados por seus respectivos pesos, e do *ensemble* de previsões de precipitação.
- Avaliar o desempenho das previsões hidrológicas obtidas.

3 REVISÃO DA LITERATURA

3.1 *Previsão hidrológica*

3.1.1 Contextualização

A previsão hidrológica, ou previsão de vazões, consiste na estimativa do volume de água escoada em um ponto de interesse durante determinado intervalo de tempo, com uma certa antecedência temporal. De acordo com a antecedência com a qual são realizadas, as previsões hidrológicas podem ser de curto, médio ou longo prazo. Previsões de curto e médio prazo geralmente possuem horizontes de previsão de algumas horas até cerca de duas semanas; a partir disso, são consideradas previsões de longo prazo ou sazonais, com horizonte de meses à frente (FAN, 2015; QUEDI, 2019; ROUNDY et al., 2019). No intervalo entre as previsões de médio e de longo prazo tem-se ainda as chamadas previsões *sub-sazonais*, cujos horizontes geralmente variam de duas semanas a dois meses à frente (QUEDI, 2019; VITART et al., 2012).

Usualmente, quanto maior o horizonte de previsão, menor é a sua acurácia, uma vez que maiores são as incertezas envolvidas. Por outro lado, a utilidade da previsão na tomada de decisões cresce à medida que se aumenta o horizonte de previsão (LETTENMAIER e WOOD, 1993). A Figura 3.1 ilustra potenciais aplicações das previsões hidrológicas, de acordo com a escala de tempo das decisões a serem tomadas.

Segundo Silva et al. (2006), as previsões de curto prazo são usualmente utilizadas para detecção de cheias e minimização dos impactos, mas podem também ser empregadas nas atividades de geração energética, abastecimento de água, irrigação e navegação. Já as previsões de longo prazo, ou sazonais, são frequentemente utilizadas para fins de planejamento de uso dos recursos hídricos, tais como definição de estratégias operativas de reservatórios de usinas hidrelétricas, avaliação e implementação de medidas contra eventos extremos (secas e inundações), entre outros. Estas últimas geralmente são orientadas para a previsão de anomalias hidrológicas persistentes na superfície terrestre (por exemplo, estiagens), que é diferente da previsão de cheias de curto prazo, cujo impacto costuma ser imediato (YUAN et al., 2015).

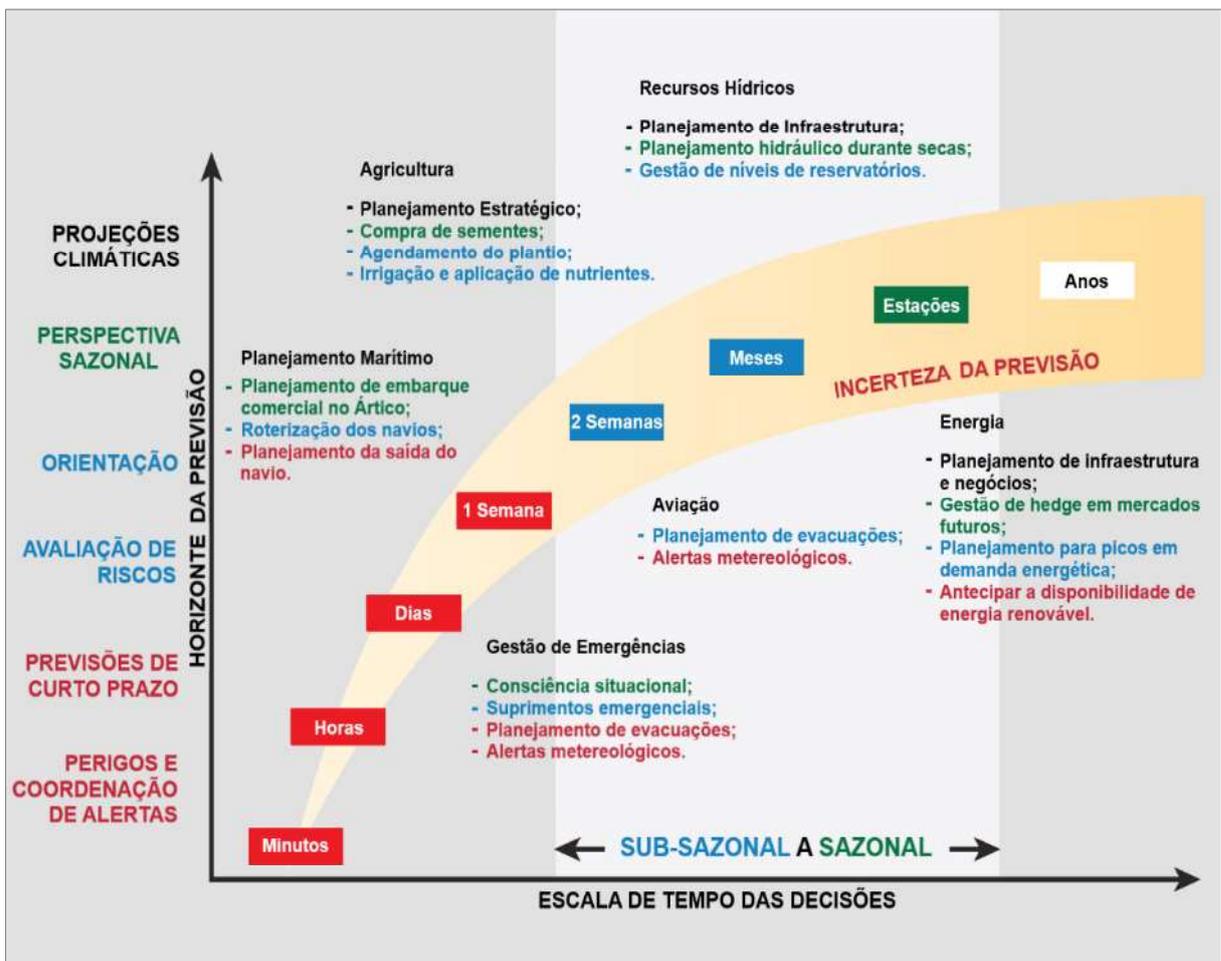


Figura 3.1 - Evolução da aplicabilidade das previsões hidrológicas de acordo com a antecedência necessária à tomada de decisões (Fonte: adaptado de NASEM, 2016).

Além da escala temporal, Sene (2010) ressalta que uma outra consideração importante acerca das previsões hidrológicas é a escala espacial em que são demandadas. Algumas categorias típicas incluem as escalas local (para aplicações de irrigação, por exemplo), de cidade e/ou comunidade, de bacia hidrográfica, regional, continental e global.

Dessa forma, as demandas das previsões hidrológicas variam em termos de escala espacial e de horizonte previsto, e um indicativo dessas demandas para aplicações práticas de previsões hidrológicas encontra-se resumido na Tabela 3.1.

Tabela 3.1 – Exemplos de demandas de previsões hidrológicas para diferentes escalas espacial e temporal. Fonte: Sene (2010).

Aplicação	Escala Espacial	Horizonte de previsão
Alertas de previsão de secas	Tipicamente regional, nacional ou continental	Varia amplamente dependendo da aplicação, mas normalmente de dias à frente até sazonais, e possivelmente horizontes maiores para secas severas
Alerta de inundação	Sub-bacia, bacia ou regional	Pode variar de alguns minutos, para inundações repentinas em desfiladeiros, até horas ou dias para rios de planície, evacuação de pessoas de vilas ou cidades, deplecionamento de reservatórios e planejamento de resposta a emergências. Além disso, a longo prazo para gestão de risco de inundação para as bacias hidrográficas mais importantes
Operação de hidrelétricas	Bacia ou regional	Horário a diário para programação de geração; diário a sazonal (ou maior) para gestão de recursos hídricos; longo prazo para operar grandes reservatórios e sistemas de múltiplos reservatórios, e para planos de investimento
Planejamento de irrigação	Local, bacia ou regional	Horas ou dias à frente para alocação de água; intrasazonal para decisões operacionais (por exemplo, fertilização, controle de pragas); sazonal para decisões de plantio / colheita; maiores horizontes para decisões de investimento
Navegação	Trechos de rios, lagos e reservatórios	Horas ou dias à frente para controle de tráfego fluvial e avisos de navegação, incluindo estimativas de níveis d'água, velocidades de corrente, alturas de ondas, formação de gelo, quebra de gelo e outros perigos
Recursos hídricos	Bacia ou regional	Normalmente, de horas a dias à frente para a gestão operacional, até semanas, anos ou décadas à frente para a gestão de bacias hidrográficas, gestão integrada de recursos hídricos e avaliações de impacto de mudanças climáticas
Abastecimento de água	Bacia ou regional	Varia de horas a dias à frente para tomada de decisões táticas em relação ao bombeamento, tratamento, etc.; para dias ou meses à frente para o planejamento operacional; e anos à frente para decisões de investimento

3.1.2 Métodos de previsão hidrológica

Para se preverem vazões, são utilizados modelos matemáticos e estatísticos que procuram representar o comportamento natural de um sistema complexo, modificado por ações antrópicas, que é uma bacia hidrográfica. Embora esses modelos incorporem as representações numéricas da física que conduz o ciclo hidrológico, existem muitas incertezas associadas aos dados de entrada e às variáveis hidrológicas que os compõem (FAN, 2015; ROUNDY et al., 2019).

Nas últimas décadas, diversas metodologias foram desenvolvidas para apoiar a previsão hidrológica. Essas metodologias estão associadas à escala da bacia, ao tempo de deslocamento da onda de cheia, às informações disponíveis e aos resultados necessários, e podem ser baseadas em: (i) propagação de ondas de cheia; (ii) transformação de chuva em vazão; e (iii) transformação de chuva em vazão com informação adicional de previsão quantitativa de precipitação (FAN, 2015; LETTENMAIER e WOOD, 1993; SILVA et al., 2006).

Os métodos de previsão de vazões por propagação da onda de cheia usualmente utilizam uma abordagem puramente hidráulica e, em geral, são mais precisos e apresentam menores incertezas associadas, uma vez que dependem exclusivamente de variáveis que podem ser medidas com maior precisão, tais como o nível de água ou a vazão nas seções a montante do ponto de interesse. Porém, tais métodos possuem como desvantagem o fato de a antecedência máxima da previsão ser limitada ao tempo de viagem da onda de cheia ao longo do trecho compreendido entre os pontos monitorados, a montante, e o ponto de interesse, a jusante (BARTHOLMES e TODINI, 2005; FAN, 2015; SILVA et al., 2006).

Segundo Fan (2015), para se preverem vazões futuras com horizontes superiores ao tempo de deslocamento da onda de cheia, podem ser incorporados à previsão os dados de precipitação observada, utilizando para tanto os modelos hidrológicos de transformação chuva-vazão. Com isso, é possível aumentar a antecedência da previsão hidrológica, uma vez que se passa a considerar também a componente do ciclo hidrológico relacionada à geração do escoamento superficial na bacia hidrográfica, provocado pela chuva.

Ademais, para se estender o horizonte das previsões hidrológicas para além do tempo de concentração da bacia modelada, são utilizadas previsões quantitativas de precipitação como forçantes desses modelos hidrológicos. Dessa forma, é possível estimar a resposta hidrológica da bacia não apenas às precipitações que já ocorreram, mas também a eventos de chuva futuros.

3.1.3 Sistemas de previsão operacionais

Ao se utilizarem modelos para previsão hidrológica em ambientes operacionais, vários fatores devem ser considerados, os quais incluem a verificação da previsão, a assimilação de dados e as incertezas acerca da previsão. Além disso, esses modelos podem ser operados dentro de um sistema de previsão automatizado, e muitas vezes algum processamento adicional de resultados é necessário para converter as previsões em produtos operacionalmente úteis (SENE, 2010).

Dessa forma, quando usados de forma operacional, ou seja, para previsão de vazões em tempo real, tais modelos geralmente são alimentados com entradas de diferentes fontes, as quais incluem observações e medições hidrometeorológicas (precipitação, nível e/ou vazão de rios, entre outros), previsões meteorológicas (previsões de precipitação, de temperatura, etc.), assim como outros tipos de dados. A combinação de tais modelos e dessa variedade de entradas constitui, portanto, um *sistema de previsão operacional*.

Como exemplos de sistemas de previsão operacionais, podem-se citar os treze *River Forecast Centers* (RFC) do *National Weather Service* (NWS), uma das seis agências científicas que compõem a *National Oceanic and Atmospheric Administration* (NOAA) do governo dos Estados Unidos (ADAMS, 2016; NWS/NOAA, 2021b), e o *European Flood Awareness System* (EFAS), operacional desde o ano de 2012 para apoiar medidas preparatórias em situações de inundações em toda a Europa (SMITH et al., 2016).

No Brasil, o Operador Nacional do Sistema (ONS) conta com um sistema de previsão de vazões naturais para todos os locais de aproveitamentos hidroelétricos do Sistema Interligado Nacional (SIN), que o permite planejar a operação eletroenergética do sistema e promover o despacho centralizado das usinas de maneira otimizada (BRIANEZI, 2015; ONS, 2020a; ONS, 2020b). Outro exemplo nacional de sistema operacional de previsões é o desenvolvido e implementado pelo Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), que tem por objetivos monitorar e antecipar a ocorrência de desastres naturais em áreas suscetíveis de todo o Brasil (CEMADEN, 2021; IVO et al., 2020).

De acordo com Sene (2010), um sistema de previsão operacional automatizado pode incluir alguns, ou todos, dos seguintes itens:

- Coleta de dados: recebimento de dados de instrumentos de medição de nível e/ou vazão, assim como dados de estações meteorológicas, geralmente associados a algum sistema de telemetria; dados de radares meteorológicos e de satélites; e previsões de serviços meteorológicos.
- Pré-processamento: validação inicial de dados a partir de verificação de faixas de valores e taxas de mudança, assim como comparações com registros próximos; preenchimento automático de falhas; e aplicação de fatores de correção pré-definidos.
- Controle de execução de modelo: programação automatizada para execução de modelos, geralmente contando com modelos alternativos mais simples em caso de falhas de tempo de execução do modelo principal, assim como fontes alternativas de dados, em caso de falhas de instrumentos.
- Assimilação de dados: uso de dados observados para inicializar estados do modelo e/ou melhorar os resultados da previsão.
- Pós-processamento: pós-processamento dos resultados da previsão em formatos tabulares, de gráficos ou mapas, ou em formatos específicos para transmissão a outros sistemas, como por exemplo, sistemas de suporte à tomada de decisão.
- Gerenciamento de dados: armazenamento dos dados de entrada e dos resultados das previsões para posterior revisão, análise de desempenho e treinamento de algoritmos de aprendizagem.

Desse modo, o uso operacional de um sistema de previsão pressupõe a disponibilidade de dados observacionais em tempo real, sejam eles provenientes de um sistema de telemetria (dados automáticos) ou de medições *in loco*, realizadas por observadores em determinados horários do dia (dados manuais). Esses dados geralmente são utilizados como entradas ou condições de contorno dos modelos de previsão, podendo também ser utilizados para contabilizar as diferenças entre os valores observados (medidos) e previstos; procedimento este denominado *assimilação de dados* ou *atualização em tempo real* (FAN, 2015; SENE, 2010). Maiores detalhes sobre esse procedimento serão discutidos em itens posteriores da presente dissertação.

Os modelos de previsão são normalmente operados pelo menos uma vez por dia, e com maior frequência durante eventos extremos, como por exemplo em cheias e/ou inundações. O sistema pode ser projetado para uso durante determinados tipos de eventos hidrológicos (e.g. inundações), ou cobrir uma gama de aplicações em gestão de recursos hídricos, operação de reservatórios, entre outros. Por fim, as previsões resultantes desse sistema operacional são pós-processadas em diferentes formatos (mapas, gráficos, tabelas, etc.) conforme a necessidade de seus usuários, para o suporte à tomada de decisões (SENE, 2010).

A posterior avaliação do desempenho dessas previsões, sejam elas *determinísticas* (uma única possível trajetória para a variável prevista) ou *probabilísticas* (associação de distribuições de probabilidade para a variável prevista), é uma etapa de extrema importância para a tomada de decisões, uma vez que permite se desenvolver uma sensibilidade quanto ao desempenho dos modelos de previsão e quanto às incertezas acerca das previsões deles resultantes. Além disso, a longo prazo, permite a detecção de possíveis erros sistemáticos e posteriores mudanças e/ou melhorias nos processos e modelos da previsão.

3.1.4 Verificação de desempenho de previsões hidrológicas

Segundo Sene (2010), a verificação das previsões hidrológicas é usualmente feita por meio da seleção de uma ou mais medidas de desempenho relevantes ao processo, comparando-se, assim, a correspondência entre os valores previstos e os posteriormente observados. No caso das previsões de vazão *determinísticas*, tais medidas de desempenho podem incluir a raiz do erro quadrático médio, o viés (erros sistemáticos), o coeficiente de eficiência – ou Eficiência de Nash-Sutcliffe (NASH E SUTCLIFFE, 1970) –, erros ao longo do tempo e quanto à magnitude dos picos de vazões, entre outros. Para tomada de decisão em tempo real, essas e outras medidas de desempenho também podem ser calculadas para diferentes antecedências, por exemplo, o erro nas vazões de pico em um horizonte de previsão de 3 horas, o pode ser particularmente útil em aplicações de previsões de curto prazo.

Já em relação às previsões *probabilísticas*, a verificação de desempenho se dá pela análise do espalhamento ou concentração dos membros e de cenários mais prováveis, sendo, portanto, mais complexa do que a verificação de previsões determinísticas (FAN, 2015). Na literatura técnica é possível encontrar uma série de métricas verificação dessas previsões, como por exemplo o *Brier Score*, o *Brier Skill Score*, o *Relative Operating Characteristic Diagram*

(Diagrama ROC), o *Reliability Diagram* (Diagrama de Confiabilidade), o *Mean Continuous Ranked Probability Score* (CRPS Médio), dentre outras.

No presente trabalho, algumas dessas métricas embasaram a avaliação do desempenho das previsões probabilísticas obtidas a partir do sistema de previsão desenvolvido, sendo elas:

- *Brier Score* (BS): métrica de avaliação de previsões probabilísticas para eventos discretos, que considera a distribuição das previsões por conjunto. O BS mede o erro quadrático médio da probabilidade de uma previsão para a ocorrência de um determinado evento, como a excedência de um certo limiar de vazão, e seus valores podem variar de 0 a 1, sendo que valores próximos de zero indicam melhores resultados (FAN, 2015; MELLER, 2012; WILKS, 2006). O BS é calculado da seguinte maneira:

$$BS = \frac{1}{n} \sum_{i=1}^n (pp_i - po_i)^2 \quad (3.1)$$

onde n é o número de pares previsão-observação; pp é a probabilidade de ocorrência prevista do evento, e po é a probabilidade de ocorrência observada do evento (0 se o evento não ocorreu; 1 se o evento ocorreu). No caso da previsão por conjunto, pp é calculada diretamente pelo número de membros que superam o limiar de vazão dividido pelo número total de membros.

- *Brier Skill Score* (BSS): medida de destreza que mensura o desempenho de uma previsão principal em relação a outra tomada como referência. Os valores de BSS podem variar de $-\infty$ a 1, de modo que valores negativos indicam que a previsão de referência possui desempenho superior à previsão principal em termos de BS (e vice-versa), e valores próximos de zero indicam que as previsões principal e de referência possuem desempenho semelhante (MELLER, 2012; WILKS, 2006). O BSS é calculado da seguinte maneira:

$$BSS = \frac{BS_p - BS_{ref}}{BS_{perf} - BS_{ref}} = 1 - \frac{BS_p}{BS_{ref}} \quad (3.2)$$

onde BS_p é o valor de BS para a previsão principal, BS_{ref} é o valor de BS para a previsão de referência e BS_{perf} é o valor de BS para a previsão perfeita, igual a zero.

- *Reliability Diagram*: diagrama que permite avaliar a confiabilidade das previsões probabilísticas para um evento discreto. Previsões probabilísticas confiáveis são aquelas em que a frequência relativa de ocorrência de tal evento, para a qual foi atribuída uma probabilidade p , tende a ser próxima de p (HSU e MURPHY, 1986; BRÖCKER e SMITH, 2007). Assim, no *Reliability Diagram* são plotadas as probabilidades previstas de ocorrência de determinado evento (eixo das abscissas) contra as probabilidades condicionais observadas de ocorrência do referido evento (eixo das ordenadas), dadas as probabilidades de previsão definidas no eixo das abscissas. Os valores resultantes são então comparados a uma linha de confiabilidade perfeita, com inclinação de 45° , de modo que desvios em relação a esta representam diferentes tipos de erros. Assim, a teoria por detrás do *Reliability Diagram* é de que um evento deve ser observado com a mesma frequência das probabilidades de ocorrência previstas ao longo de uma grande amostra de previsões (FAN, 2015).

Maiores detalhes sobre essas e outras métricas comumente utilizadas para a verificação de previsões probabilísticas podem ser encontrados nos trabalhos de Wilks (2006), Stanski et al., (1989), Fan (2015), Lettenmaier e Wood (1993), Brown et al. (2010) e Bröcker e Smith (2007).

3.2 Modelos hidrológicos

Os modelos hidrológicos são ferramentas utilizadas para representação dos processos hidrológicos que ocorrem em uma bacia hidrográfica, tais como: precipitação, interceptação vegetal, evapotranspiração, infiltração, percolação, escoamento superficial e subterrâneo, etc. Essa representação é realizada a partir de formulação e equacionamento matemáticos e trata-se de uma simplificação da realidade, dada a grande complexidade e variabilidade dos processos envolvidos no ciclo hidrológico (RENNÓ e SOARES, 2000; SARAIVA, 2010; TUCCI, 2005).

As finalidades de uso dos modelos hidrológicos podem ser várias, dentre elas: estimação da vazão em bacias sem monitoramento fluviométrico; simulação de evento de cheias, para mitigação dos possíveis impactos; estudos de avaliação do impacto da mudança de uso do solo no escoamento superficial de uma bacia; e, como exposto anteriormente, para previsão hidrológica, para fins de planejamento de uso do recurso hídrico e antecipação de eventos extremos, subsidiando a ação de medidas preventivas.

Dessa forma, no processo de escolha do modelo hidrológico para a representação de um sistema natural, deve-se ter em conta os objetivos pretendidos com a modelagem, as limitações do

modelo na representação dos processos hidrológicos e a quantidade e qualidade dos dados a serem utilizados em conjunto com o modelo (SARAIVA, 2010; TUCCI, 2005).

Segundo Tucci (2005), os modelos hidrológicos surgiram devido à necessidade de se obterem séries de vazões mais extensas para uso em projetos de recursos hídricos. Assim, uma vez calibrado o modelo hidrológico para a bacia de interesse, foi possível estender a informação fluviométrica a partir das séries de precipitação, normalmente mais longas.

Além disso, o autor afirma que, devido às modificações na bacia hidrográfica provocadas por alterações no uso do solo, muitas séries de vazão deixaram de ser homogêneas e estacionárias. Desse modo, o uso dos modelos hidrológicos possibilitou reanalisar ou estimar as vazões desconhecidas para os novos cenários existentes ou previstos para as bacias, a partir dos dados de precipitação registrados.

3.2.1 Contextualização histórica

O primeiro modelo hidrológico amplamente utilizado para estimar o escoamento das chuvas foi o Método Racional, publicado por Thomas Mulvany em 1851 (ALMEIDA e SERRA, 2017; FAYAL, 2008; SITTERSON et al., 2017; TODINI, 2007). Nesse método, Mulvany utilizou a intensidade da chuva, a área de drenagem e um coeficiente de escoamento para determinar o pico de vazão em bacias de drenagem pequenas ou montanhosas. Todini (2007) afirma que aplicações do Método Racional no dimensionamento de esgotos surgiram na literatura a partir do final do século XIX.

Segundo Todini (1988), durante a década de 1920, com o surgimento da necessidade da modelagem de bacias maiores, foram introduzidas modificações no Método Racional, de forma a lidar com a distribuição não homogênea, temporal e espacialmente, das precipitações e das características da bacia. De acordo com o autor, esse “Método Racional Modificado” pode ser visto como o primeiro modelo básico chuva-vazão baseado em uma função de transferência para avaliar os diferentes tempos de viagem na bacia.

A partir de 1930, importantes avanços se deram na modelagem hidrológica, quando as agências governamentais dos países desenvolvidos começaram a desenvolver seus próprios programas de pesquisas hidrológicas, elaborando modelos que tratavam de descrever os processos relacionados a cada componente do ciclo hidrológico (FAYAL, 2008). Em 1932, surge o

conceito do Hidrograma Unitário, proposto por Sherman e baseado no princípio da superposição de efeitos, permitindo a previsão do hidrograma completo de cheia a partir da chuva amostrada em intervalos constantes (FAYAL, 2008; SITTERSON et al., 2017; TODINI, 1988; TODINI, 2007).

O interesse dos hidrólogos acelerou-se então com o princípio do Hidrograma Unitário, uma vez que agora eles tinham condições de reproduzir não apenas os picos de vazão, mas também os hidrogramas gerados por tempestades mais complexas. Assim, a partir do final dos anos trinta e durante a década de 1940, várias técnicas foram propostas para melhorar a objetividade dos métodos e resultados da modelagem hidrológica, e a partir de então as técnicas de análise estatística passaram a ser utilizadas (TODINI, 1988).

No entanto, o verdadeiro avanço na modelagem hidrológica ocorreu somente na década de 50, com a disponibilidade de maior poder computacional e o aprimoramento das técnicas numéricas e estatísticas. A partir disso, houve um acelerado desenvolvimento dos chamados modelos ditos *semi-conceituais de transformação chuva-vazão*, os quais utilizavam funções empíricas e a equação da continuidade na representação dos processos hidrológicos (FAYAL, 2008; TODINI, 1988; TUCCI, 2005). Em paralelo aos modelos semi-conceituais, foram desenvolvidos os modelos *empíricos*, ou modelos “caixa-preta”, constituídos por funções matemáticas que não possuíam relação com o comportamento físico dos processos hidrológicos envolvidos (FAYAL, 2008; TUCCI, 2005).

Segundo Almeida e Serra (2017), com a disseminação do uso de computadores nas décadas de 60 e 70 e com a maior disponibilidade de dados hidrometeorológicos, a variabilidade espacial das características da bacia passou a ser abordada na modelagem hidrológica, com o intuito de se obter uma melhor interpretação física da resposta dessas bacias. Nesse sentido, iniciou-se o desenvolvimento de modelos com maior base física, procurando-se estabelecer relações entre as características físicas do sistema e os parâmetros, de forma a reduzir-se o empirismo na estimativa destes últimos.

Ainda na década de 1970, devido ao fato de os modelos disponíveis possuírem muitos parâmetros, surgiu uma tendência de se usarem somente os parâmetros dos processos hidrológicos mais importantes. Percebeu-se que, mesmo com essa simplificação, era possível obter resultados equivalentes aos dos modelos que representavam quase todos os processos, devido à pequena sensibilidade dos demais parâmetros. Assim, passaram a surgir modelos com

um número reduzido de funções e parâmetros, os quais mostraram-se mais eficientes para a engenharia, tais como o modelo IPH II, apresentado por Tucci et al. no ano de 1981, e o SMAP, publicado por Lopes et al. também em 1981 (FAYAL, 2008).

Deste então, diversos modelos hidrológicos têm sido desenvolvidos, dada a grande variabilidade física das bacias hidrográficas e dos processos envolvidos no ciclo hidrológico. Em geral, esses modelos se diferenciam em função dos dados utilizados, da discretização espacial e temporal, das prioridades na representação dos processos hidrológicos e dos objetivos e escalas de aplicação (TUCCI, 2005), podendo ser utilizados para as mais variadas finalidades.

3.2.2 Classificação dos modelos hidrológicos

Os modelos hidrológicos existentes podem ser agrupados sobre diferentes aspectos, não havendo um consenso quanto aos critérios para essa classificação. Embora existam muitas maneiras de classificá-los, nem todos os modelos se encaixam em uma única categoria, uma vez que são desenvolvidos para uma variedade de propósitos e podem conter elementos de diferentes categorias (SARAIVA, 2010; SINGH, 1995 apud SITTERSON et al., 2017).

Uma das principais classificações dentro da modelagem hidrológica é a que diferencia os modelos *estocásticos* dos *determinísticos*. Um modelo é dito estocástico quando pelo menos uma das variáveis envolvidas tem comportamento aleatório, e a representação do comportamento da série observada se dá por meio de algum modelo de série temporal. Por outro lado, caso os conceitos de probabilidade e a chance de ocorrência das variáveis envolvidas no processo sejam negligenciados, o modelo é considerado determinístico. No entanto, mesmo quando as variáveis de entrada são aleatórias, um modelo pode ainda assim ser determinístico, caso cada valor de entrada produza um único valor de saída (ALMEIDA e SERRA, 2017; RENNÓ E SOARES, 2000; TUCCI, 2005).

Dentre os modelos determinísticos, encontram-se os denominados *modelos de transformação chuva-vazão*, definidos por Tucci (2005) como sendo aqueles que representam a parte terrestre do ciclo hidrológico, ou seja, aquela entre o volume precipitado e o escoamento em forma de vazão. Para tanto, são utilizados diferentes algoritmos que buscam representar os processos relacionados a essa transformação. Tais modelos podem ser classificados, dentre outras formas, de acordo com a discretização da bacia modelada e representação espacial dos processos do modelo (concentrados ou distribuídos), assim como com a sua estrutura e o tipo de relação entre

variáveis de entrada utilizadas na modelagem (empíricos, conceituais ou físicos) (SARAIVA, 2010; SITTERSON et al., 2017; TUCCI, 2005).

Os modelos ditos *concentrados* são aqueles em que não é considerada a variabilidade espacial das características da bacia e dos dados de entrada, de forma que toda a bacia é representada por precipitações médias e os processos hidrológicos, por variáveis concentradas no espaço. Em geral, são aplicados para bacias pequenas, nas quais a distribuição espacial dos parâmetros e das variáveis não compromete os resultados. Por outro lado, os modelos *distribuídos* permitem a subdivisão da área modelada em unidades menores e consideradas homogêneas, reconhecendo, portanto, a distribuição espacial dos parâmetros e das variáveis e permitindo a espacialização dos dados de entrada, como por exemplo, a precipitação (ALMEIDA e SERRA, 2017; TUCCI, 2005).

Em relação à estrutura, os modelos podem variar desde simples a mais complexos, de acordo com as equações que governam o escoamento. Na escala da complexidade, os modelos *empíricos* são os que possuem estrutura mais simplificada, uma vez que não há a preocupação com a representação dos processos hidrológicos envolvidos, apenas com as relações estatísticas não-lineares entre entradas e saídas. Em seguida encontram-se os modelos *conceituais*, que possuem alguma fundamentação física e se baseiam em armazenamentos de reservatórios e equações simplificadas dos processos hidrológicos, fornecendo uma ideia conceitual do comportamento da bacia. Já os modelos *físicos* são os mais complexos, uma vez que representam os processos hidrológicos por meio das equações diferenciais e leis físicas que os governam, buscando retratar as respostas hidrológicas reais da bacia modelada (ALMEIDA e SERRA, 2017; SARAIVA, 2010; SITTERSON et al., 2017).

Segundo Collischonn (2001), os modelos de base física geralmente são os que melhor representam os processos físicos de uma bacia hidrográfica e se caracterizam por possuírem parâmetros com significado físico, os quais podem, portanto, ser estimados a partir de medidas reais. No entanto, quando há carência dessas informações ou dificuldade em obtê-las, os modelos de base física costumam ser substituídos pelos modelos conceituais. Estes mantêm uma base física mínima, uma vez que se baseiam em representações matemáticas simplificadas dos processos do ciclo hidrológico, mas, devido ao fato de seus parâmetros não poderem ser medidos diretamente, necessitam de uma etapa de ajuste ou calibração.

Diante do exposto, e somado à limitação do monitoramento e, portanto, da disponibilidade da informação hidrometeorológica, deve-se ter preferência por modelos hidrológicos que necessitem de um menor número de variáveis de entrada e que possuam um reduzido número de parâmetros a serem estimados. Esta última condição está relacionada ao princípio da *parcimônia* na abordagem estatística, que, no que tange aos modelos hidrológicos, refere-se à capacidade destes em representar o comportamento hidrológico de uma bacia com o menor número de parâmetros possível (BRAVO et al., 2007; SARAIVA, 2010; TUCCI, 2005).

Esse critério foi determinante na escolha do modelo hidrológico a ser utilizado no presente trabalho. Além de simples e parcimonioso, é um modelo que tem sido amplamente utilizado no setor elétrico brasileiro, inclusive pelo próprio Operador Nacional do Sistema (ONS, 2018). Trata-se do modelo SMAP, cuja descrição é realizada no item a seguir.

3.2.3 O modelo SMAP

O modelo SMAP (*Soil Moisture Accounting Procedure*) é um modelo determinístico e conceitual do tipo transformação chuva-vazão, publicado por Lopes et al. (1981). O modelo simula o balanço da umidade do solo, o qual é atualizado continuamente por meio das condições iniciais fornecidas como dados de entrada, fundamentado em reservatórios fictícios não lineares que representam as diferentes camadas do solo. Para o cálculo da chuva efetiva, é utilizada a equação de escoamento superficial do *Soil Conservation Service* (SCS), do Departamento de Agricultura dos Estados Unidos (LOPES et al., 1981; LOPES, 1999; ONS, 2018; SARAIVA, 2010).

O SMAP foi originalmente desenvolvido para o intervalo de tempo diário, com três reservatórios, e posteriormente foram apresentadas as versões horária e mensal, adaptando-se algumas modificações em sua estrutura. Uma das modificações foi a adição e a supressão de um reservatório nas versões horária e mensal, respectivamente, conforme ilustrado nos diagramas esquemáticos da Figura 3.2.

Na versão horária, o reservatório de canal (R_c) foi adicionado de forma a representar o amortecimento dos canais de drenagem, que passa a ser sensível nesse intervalo. Já na versão mensal, a supressão do reservatório de superfície (R_{sup}) se justifica pelo fato do amortecimento desse reservatório ocorrer em intervalos inferiores a um mês. Consequentemente, o conceito de capacidade de campo ($CAPC$), utilizado no reservatório do solo, também é suprimido.

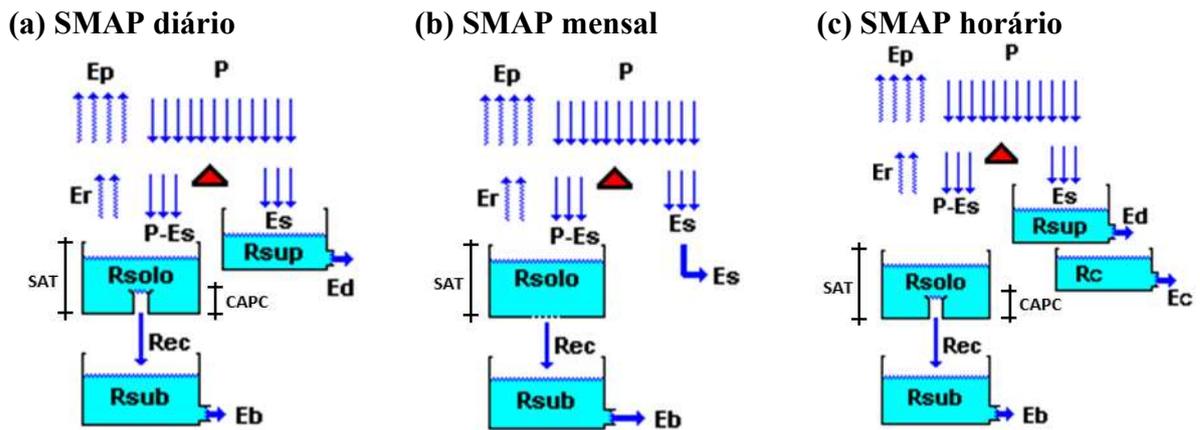


Figura 3.2 - Diagramas esquemáticos do modelo SMAP, em suas versões (a) diária, (b) mensal e (c) horária (Fonte: adaptado de Lopes, 1999).

Uma outra modificação realizada na versão mensal é com relação à determinação da precipitação efetiva. Dado que nesse intervalo de cálculo se trabalha com a soma de inúmeros eventos de precipitação, e uma vez que a técnica do SCS somente se aplica a cada evento de precipitação, esta foi substituída por Lopes et al. (1981) por uma função exponencial. Essa única função substitui uma família de curvas do SCS que dependem da precipitação efetiva, e é dada por:

$$Es = P \times TU^{E2} \quad (3.3)$$

onde Es é o escoamento superficial (em mm), P é a precipitação (em mm) e TU é a taxa de umidade do solo. Dessa forma, no SMAP mensal, o controle do escoamento superficial passa a ser exercido pelo parâmetro $E2$. Além disso, a recarga do reservatório subterrâneo $Rsub$, que na versão diária ocorria quando a umidade do solo era superior à capacidade de campo, passa a ser calculada em função do teor de umidade do solo, através da Equação (3.4):

$$Rec = Rsolo \times TU^4 \times CREC \quad (3.4)$$

onde Rec é a recarga subterrânea (em mm), $Rsolo$ é a umidade do solo (em mm) e $CREC$ é o coeficiente de recarga.

Dada a finalidade de uso do SMAP para a previsão de longo prazo das afluências médias mensais ao reservatório de Itaipu, utilizou-se a versão mensal do modelo. Nesta versão, o modelo conta com quatro parâmetros calibráveis, quatro funções de transferência e os dois reservatórios matemáticos fictícios indicados na Figura 3.2b – o reservatório de solo (*R_{solo}*), que representa a zona aerada do solo, e o reservatório subterrâneo (*R_{sub}*), que simula a zona saturada do solo. Os dados necessários para sua calibração são as séries mensais de precipitação (em mm), as séries de vazões médias diárias (em m³/s) e os dados de evapotranspiração potencial da bacia (em mm).

Os quatro parâmetros calibráveis do SMAP Mensal são:

- *SAT*: capacidade de saturação do solo (mm);
- *CREC*: coeficiente de recarga (ad.);
- *K*: constante de recessão do reservatório do solo (mês⁻¹);
- *E2*: parâmetro de escoamento superficial (ad.).

Na Tabela 3.2 são mostradas as faixas de variação desses parâmetros, as quais foram obtidas por Lopes (1999) a partir de sua experiência com a aplicação do modelo em bacias de diversas regiões brasileiras.

Tabela 3.2 – Limites dos parâmetros calibráveis do SMAP, em sua versão mensal.
Fonte: Lopes (1999).

Parâmetro	Limite Inferior	Limite Superior
SAT (mm)	400	5.000
CREC (ad.)	0	0,7
K (mês ⁻¹)	0,5	0,9
E2 (ad.)	0,1	10

A inicialização das variáveis de estado dos reservatórios matemáticos *R_{solo}* e *R_{sub}* é efetuada a partir das variáveis *SOLIN* e *SUBIN* (Equações (3.5) e (3.6)), que fornecem as condições iniciais ao modelo, e são atualizadas a cada mês, por meio das Equações (3.7) e (3.8):

Inicialização:

$$R_{solo(1)} = SOLIN \times SAT \quad (3.5)$$

$$R_{sub(1)} = \frac{SUBIN \times AD \times 2630}{1 - K} \quad (3.6)$$

sendo $SOLIN$ a umidade inicial do solo (%), $SUBIN$ a vazão de base inicial (m^3/s), AD a área de drenagem da bacia modelada (km^2) e 2630 o fator de conversão de unidades para obter R_{sub} em mm. Dessa forma, para a correta inicialização das variáveis de estado do modelo, os valores estimados de $SOLIN$ e $SUBIN$ devem ser ajustados de forma que coincida a vazão simulada no início do hidrograma, e devem ser novamente estimados caso haja alteração do período simulado.

Atualização:

$$R_{solo(i+1)} = R_{solo(i)} + P_{(i+1)} - Es_{(i+1)} - Er_{(i+1)} - Rec_{(i+1)} \quad (3.7)$$

$$R_{sub(i+1)} = R_{sub(i)} + Rec_{(i+1)} - Eb_{(i+1)} \quad (3.8)$$

As quatro funções de transferência do SMAP mensal são representadas pelo escoamento superficial (Es), pela evapotranspiração real (Er), pela recarga subterrânea (Rec) e pelo escoamento básico (Eb), e são calculadas a cada mês, a partir das Equações (3.9) a (3.12):

$$Es_{(i+1)} = f1 \times P_{(i+1)} \quad \text{onde: } f1 = TU_{(i+1)}^{E2} \quad (3.9)$$

$$Er_{(i+1)} = f2 \times Ep_{(i+1)} \quad f2 = TU_{(i+1)} \quad (3.10)$$

$$Rec_{(i+1)} = f3 \times R_{solo(i)} \quad f3 = CREC \times TU_{(i+1)}^4 \quad (3.11)$$

$$Eb_{(i+1)} = f4 \times R_{sub(i)} \quad f4 = 1 - K \quad (3.12)$$

sendo Ep a evapotranspiração potencial (mm) e TU a taxa de umidade atual do solo, atualizada da seguinte maneira:

$$TU_{(i+1)} = \frac{Rsolo_{(i)} + dsol_{(i+1)}}{SAT} \quad (3.13)$$

Onde:

$$dsol_{(i+1)} = 0,5 \times (P_{(i+1)} - P_{(i+1)} \times TU_{(i)}^{E2} - Ep_{(i+1)} \times TU_{(i)} - Rsolo_{(i)} \times CREC \times TU_{(i)}^4) \quad (3.14)$$

$$TU_{(i)} = \frac{Rsolo_{(i)}}{SAT} \quad (3.15)$$

sendo *dsol* a variação do nível do reservatório *Rsolo*.

O eventual transbordo do reservatório do solo é transformado em escoamento superficial e, por fim, o cálculo da vazão é dado pela soma dos escoamentos superficiais e subterrâneo no ponto de controle (saída) da bacia, ou seja:

$$Q = (Eb + Es) \times \frac{AD}{2630} \quad (3.16)$$

3.2.4 Assimilação de dados

Conforme pontuado anteriormente, um dos fatores a serem considerados em um sistema de previsão operacional baseado em modelos hidrológicos é o da assimilação de dados, que tem se mostrado promissor na melhoria da precisão das previsões e na quantificação das incertezas iniciais da previsão (LIU et al., 2012; YUAN et al., 2015).

Quando os modelos hidrológicos são utilizados para previsão de vazões em tempo real, é bastante comum que a vazão simulada no início da previsão seja diferente do valor observado naquele mesmo instante, e essa diferença pode provocar erros nos intervalos de tempo iniciais das previsões e se propagar ao longo de todo o horizonte de previsão. Nesse sentido, faz-se oportuna a etapa de *assimilação de dados*, ou *atualização em tempo real*, que consiste em um processo de retroalimentação, a partir do qual as observações são utilizadas para inicializar os estados e as condições de contorno do modelo hidrológico antes do início de cada previsão, buscando-se aproximar as condições simuladas pelo modelo das condições observadas *in loco* (FAN, 2015; SENE, 2010).

As técnicas de assimilação de dados se diferem de acordo com as variáveis modificadas, as quais geralmente se resumem em (FAN, 2015; HOUSER et al., 2012; LIU et al., 2012; SENE, 2010; SILVA, 2015; WMO, 1992):

- Dados de entrada: ajuste nos dados de entrada ou forçantes do modelo;
- Variáveis de estado: ajuste nos estados ou armazenamentos do modelo, buscando-se aproximar as simulações das observações;
- Parâmetros: ajuste ou substituição dos parâmetros do modelo com dados observacionais;
- Correção do erro: correção direta das saídas do modelo por um fator de correção integrado no tempo, sem modificar suas variáveis internas.

Segundo a WMO (1992), essas técnicas podem ser utilizadas de maneira isolada ou ser combinadas entre si, e podem consistir em métodos totalmente automatizados (por exemplo, filtros de Kalman) ou manualmente interativos (por tentativa e erro).

A assimilação de dados surgiu na Meteorologia, com o objetivo de se melhorarem as previsões meteorológicas operacionais (HOUSER et al., 2012; KALNAY, 2003). Na Hidrologia, as técnicas de assimilação são bastante similares às utilizadas na Meteorologia, compartilhando inclusive algumas terminologias (SENE, 2010). A Tabela 3.3 resume algumas dessas técnicas, com base no tipo de variável que é modificada.

Tabela 3.3 - Exemplos de técnicas de assimilação de dados em aplicações de previsão hidrológica (Fonte: adaptado de Sene, 2010).

Tipo	Terminologias alternativas	Exemplos de técnicas
Atualização dos dados de entrada	Pós-processamento meteorológico, pré-processamento hidrológico	Filtro de Kalman, <i>Bayesian Model Averaging</i> (BMA), ajustes manuais pelo previsor
Atualização dos estados	Atualização em tempo real	Geralmente são específicas do modelo, mas podem incluir a alteração dos estados (armazenamento de reservatórios) em modelos conceituais chuva-vazão; Filtro de Kalman; Filtro de Partículas; técnicas variacionais para modelos distribuídos; e simples substituição de valores observados até o instante atual

Tipo	Terminologias alternativas	Exemplos de técnicas
Atualização dos parâmetros	Calibração “ <i>on-the-fly</i> ”	Específicas do modelo, mas podem incluir ajustes nos coeficientes de rugosidade em modelos hidrodinâmicos, coeficientes de escoamento superficial, em modelos hidrológicos chuva-vazão; e ajustes em outros parâmetros, usando métodos empíricos, Filtros de Kalman, etc.
Atualização das saídas	Correção do erro, correção das saídas, ajustes em tempo real, atualização em tempo real, pós-processamento hidrológico	Técnicas de análise de séries temporais (e.g. modelos Autorregressivos Integrados de Média Móvel (ARIMA)), redes neurais, e ajustes manuais pelo previsor (e.g. coeficientes de correlação)

A assimilação de dados geralmente é recomendada como uma boa prática em previsões hidrológicas, desde que a qualidade e disponibilidade de dados sejam suficientes para sustentar o método utilizado. A qualidade desses dados é fundamental para garantir a qualidade da previsão atualizada após a assimilação; caso contrário, podem ser inseridos erros na previsão e, com isso, haver uma piora em seu desempenho. Além disso, ressalta-se que, mesmo que aplicada, a assimilação de dados não exclui a necessidade de se ter um modelo bem calibrado, capaz de representar de forma satisfatória a resposta hidrológica a uma ampla gama de tipos de eventos (FAN, 2015; SENE, 2010).

A atualização dos estados do modelo foi a técnica de assimilação de dados utilizada no presente trabalho, para a inicialização das variáveis de estado do modelo hidrológico no instante imediatamente anterior ao da previsão. De acordo com Sene (2010), esse tipo de técnica é amplamente utilizado para a inicialização de modelos chuva-vazão conceituais, geralmente feita de maneira interna ao modelo, e é realizada em consequência do acúmulo de erros no armazenamento dos reservatórios conceituais. Tal acúmulo ocorre em função da assimilação pelas variáveis de estado de todas as fontes de incerteza associadas à modelagem – dados de entrada, estrutura, parâmetros e/ou saída dos modelos – a cada passo de tempo da simulação (SILVA, 2015; WMO, 1992).

Ademais, por ser uma atualização interna ao modelo, esse tipo de técnica possui a vantagem de se propagar espacial e temporalmente pela simulação, uma vez que age diretamente no modelo hidrológico (FAN, 2015).

3.3 Previsão de precipitação

Conforme mencionado anteriormente, o uso de previsões quantitativas de precipitação, ou QPF (*Quantitative Precipitation Forecast*), permite estender o horizonte das previsões hidrológicas para além do tempo de concentração da bacia modelada. No que diz respeito ao tempo de antecedência, as QPF podem ser classificadas como (i) *nowcasting*, ou previsão de curtíssimo prazo, para antecedências de 0 a 6 horas; (ii) previsão de curto prazo, para antecedências entre 6 e 24 horas; (iii) previsão de médio prazo, com horizontes de 2 a 14 dias de antecedência; (iv) previsão sub-sazonal, com horizontes de 2 semanas a 2 meses; e (iv) previsão de longo prazo ou sazonal, de meses no horizonte (ALLEY et al., 2019; COLLIER e KZYYSZTOFOWICZ, 2000; QUEDI, 2019; SILVA et al., 2006; VITART et al., 2012).

As previsões hidrológicas que utilizam as QPF são bastante úteis, uma vez que estimam vazões para horizontes maiores e permitem a antecipação dos cenários hidrológicos futuros. Essas previsões, no entanto, possuem a desvantagem de apresentarem maiores incertezas, as quais estão fortemente relacionadas às previsões de precipitação e suas respectivas incertezas, que tendem a aumentar à medida que se amplia o horizonte da previsão (FAN, 2015; GALVÃO, 1999; QUEDI, 2019; COLLISCHONN, 2001).

A QPF é uma das diversas variáveis meteorológicas geradas pelas previsões numéricas de tempo, ou NWP (*Numerical Weather Predictions*). As NWP geralmente são operadas pelos Serviços Meteorológicos Nacionais e um pequeno número de organizações internacionais e de pesquisa (SENE, 2010), e são a forma de dados dos modelos meteorológicos com a qual se tem mais familiaridade no dia a dia (NOAA, 2021a).

3.3.1 Modelos meteorológicos

Os modelos meteorológicos consistem em sistemas de equações prognósticas tridimensionais – equações de Navier-Stokes e de continuidade de massa, e leis da termodinâmica e dos gases ideais – sobre as quais as mudanças do vento, pressão, umidade, densidade e temperatura são descritas na atmosfera (BAUER et al., 2015; CASSARDO, 2009).

De acordo com a área de abrangência, esses modelos podem ser classificados em *globais* e *regionais*. Os modelos globais simulam todo o globo terrestre e possuem resolução espacial pouco detalhada, de ordem de dezenas de quilômetros. Já os modelos regionais, ou de área

delimitada, simulam apenas uma região do globo, conforme a resolução desejada. Tais modelos possuem maior resolução espacial e conseqüentemente, maior detalhamento, o que os permite levar em conta uma descrição mais acurada do terreno, como o uso do solo e a topografia e, assim, reproduzir com maior precisão os fenômenos meteorológicos de escalas espaciais e temporais heterogêneas, tais como frentes, sistemas convectivos de mesoescala e precipitações orográficas (FAN, 2015; KALNAY, 2003).

Os modelos meteorológicos regionais são operados por muitos países; no entanto, somente alguns centros regionais e internacionais específicos operam modelos globais. Atualmente, a Organização Meteorológica Mundial (OMM) reconhece treze Centros de Produção Global, ou GPCs (*Global Producing Centres*), oficialmente designados para operarem modelos meteorológicos de escala global. Tais centros, e suas respectivas localizações, encontram-se resumidos na Tabela 3.4.

Tabela 3.4 - Centros de Produção Global da OMM (Fonte: WMO, 2020).

País	Organização	Localização
África do Sul	<i>South African Weather Service</i>	Pretória
Alemanha	<i>Deutscher Wetterdienst</i>	Offenbach
Austrália	<i>Bureau of Meteorology</i>	Melbourne
Brasil	Centro de Previsão de Tempo e Estudos Climáticos (CPTEC)	Cachoeira Paulista
Canadá	<i>Meteorological Service of Canada</i>	Montreal
China	<i>National Climate Center of China Meteorological Administration</i>	Pequim
Coreia do Sul	<i>Korean Meteorological Administration</i>	Seul
Estados Unidos	<i>NOAA NCEP Climate Prediction Centre</i>	Washington
França	<i>Meteo France</i>	Toulouse
Japão	<i>Japan Meteorological Agency</i>	Tóquio
Reino Unido	<i>Met Office</i>	Exeter
Rússia	<i>Hydrometeorological Centre of Russia</i>	Moscú
Internacional (apoiado por 31 Estados-Membros)	<i>European Centre for Medium-Range Weather Forecasts (ECMWF)</i>	Reading, Reino Unido

Uma vez que simulam apenas uma parte do globo, os modelos regionais geralmente utilizam os modelos globais em suas condições iniciais e de contorno. Esse procedimento é denominado “técnica de modelos aninhados”, de forma que um modelo regional com resolução mais detalhada é utilizado para a previsão do tempo em uma região delimitada, enquanto que um modelo de menor resolução é usado para representar a circulação global e fornecer as condições de contorno ao modelo regional. Assim, essas condições de contorno devem ser o mais precisas possível pois, caso contrário, a solução interna dos modelos regionais se deteriora rapidamente (COLLISCHONN, 2001; KALNAY, 2003).

Dentre os modelos meteorológicos estão os modelos de previsão numérica do tempo, ou NWP, que, com base nas condições oceânicas e atmosféricas atuais, supostamente conhecidas, e nas condições de contorno (radiação solar, refletividade terrestre, cobertura de gelo, entre outras), buscam prever os estados futuros da atmosfera, com antecedências que podem ir de alguns dias até anos no horizonte (BAUER et al., 2015; CASSARDO, 2009). Nesses modelos, podem ainda ser incluídas as várias camadas do solo, de forma a simular a interação da atmosfera com a superfície terrestre e, particularmente para previsões de médio a longo prazo, um modelo de oceano (por exemplo, um modelo de ondas) também pode ser incluído (SENE, 2010).

De acordo com Kalnay (2003), tanto os modelos globais quanto os regionais são utilizados para as NWP. Os primeiros geralmente são utilizados para orientação das previsões de médio prazo e para simulações climáticas, a partir dos modelos acoplados de circulação geral, os quais serão definidos em um item específico deste documento. Já os modelos regionais são utilizados apenas para as previsões de curto prazo, uma vez que, após determinado período (proporcional ao tamanho do modelo), a informação das condições iniciais desses modelos de alta resolução é “engolida” pela influência das condições de contorno fornecidas pelo modelo global.

Atualmente, os modelos de previsão numérica de tempo são simulados diariamente em diversos centros de meteorologia ao longo de todo o globo terrestre (SILVA et al., 2006), e várias pesquisas têm sido desenvolvidas para melhorar a acurácia desses modelos. No Brasil, o Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), do Instituto Nacional de Pesquisas Espaciais (INPE), e o Instituto Nacional de Meteorologia (INMET) são os principais responsáveis pelas pesquisas em NWP do país. Nos EUA, essas pesquisas ocorrem nos laboratórios nacionais da NOAA (*National Oceanic and Atmospheric Administration*), da NASA (*National Aeronautics and Space Administration*) e do NCAR (*National Center for*

Atmospheric Research). Em outros países, as principais pesquisas ocorrem em grandes centros operacionais nacionais e internacionais, como o *European Centre for Medium-Range Weather Forecasts* (ECMWF), o *National Centers for Environmental Prediction* (NCEP) e os serviços meteorológicos do Reino Unido, França, Alemanha, Canadá, Japão, Austrália, entre outros. O compartilhamento de dados e melhorias de pesquisa é uma longa tradição na Meteorologia, de forma que o progresso na ciência da previsão ocorre em muitas frentes, e todos os países se beneficiam com esse progresso (KALNAY, 2003).

3.3.2 Evolução das previsões numéricas de tempo

As raízes das previsões numéricas de tempo remetem ao nome de Vilhelm Bjerknes, um físico norueguês considerado o pai da meteorologia moderna, que em 1904 publicou um artigo sugerindo que seria possível prever o tempo a partir da integração um sistema de equações diferenciais parciais não lineares de movimento da atmosfera. Sua pesquisa revelou a interação fundamental entre a dinâmica dos fluidos e a termodinâmica, e foi a primeira a reconhecer explicitamente que o estado futuro da atmosfera é, em princípio, completamente determinado por seu estado inicial e por suas condições de contorno. Tal pesquisa acabou se tornando a base hidrodinâmica para a previsão do tempo, que passou a dominar a meteorologia a partir de então (GOLDING et al., 2006; KALNAY, 2003; NOAA, 2021b).

Contudo, coube a Lewis Fry Richardson, um matemático britânico, sugerir os meios práticos para a solução do sistema de equações definido por Bjerknes (JACOBSON, 2005; KALNAY, 2003). De acordo com Kimura (2002), a previsão numérica do tempo foi sugerida pela primeira vez no ano de 1922, quando Richardson publicou o livro "*Weather Prediction by Numerical Process*". Nesse livro, Richardson se propôs a prever a mudança da circulação atmosférica por integração numérica das equações governantes da circulação atmosférica – equações de Navier-Stokes no referencial rotativo, equação da continuidade e a primeira lei da termodinâmica –, calculando, manualmente, uma previsão para a mudança na pressão em um único ponto ao longo de um período de seis horas.

Embora a previsão de Richardson posteriormente tenha se revelado completamente irreal, seus esforços foram um vislumbre do futuro da previsão do tempo àquela época. Somente em 1950, com a invenção do primeiro computador eletrônico, o ENIAC (*Electronic Numerical Integrator and Computer*), e o notável progresso na meteorologia dinâmica, é que se conseguiram os resultados de uma previsão numérica do tempo bem sucedida (GOLDING

et al., 2006; JACOBSON, 2005; KIMURA, 2002; NOAA, 2021b; PU e KALNAY, 2019; SILVA et al., 2006).

Desde então, diversos e contínuos desenvolvimentos foram sendo realizados nas NWP, com consequente aumento em sua acurácia (ALLEY et al., 2019; KALNAY, 2003; PU e KALNAY, 2019), tais como:

- Amadurecimento dos sistemas de observação global na década de 1970 (Figura 3.3) e maior disponibilidade de dados observacionais, especialmente dados de sensoriamento remoto por satélite e de radares e aeronaves sobre o oceano;
- Uso de métodos mais precisos de assimilação de dados, resultando em melhores condições iniciais para os modelos;
- Avanços significativos na tecnologia computacional e aumento da potência dos supercomputadores, permitindo resoluções numéricas muito mais estáveis e precisas, e menos aproximações nos modelos atmosféricos operacionais;
- Rápido desenvolvimento de parametrizações físicas, permitindo representação mais aprimorada de processos físicos de pequena escala (nuvens, precipitação, transferências turbulentas de calor, umidade, momento e radiação) dentro dos modelos.

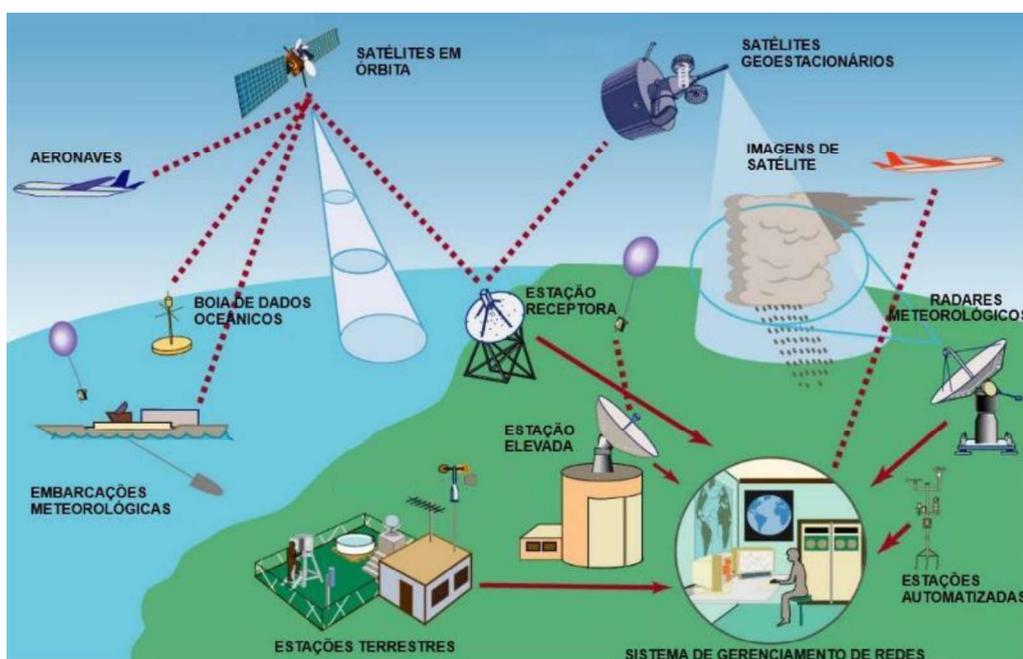


Figura 3.3 - Sistema de observação global: instalações de observação em superfície, no mar, no ar e no espaço sideral, pertencentes e operadas pelos países membro da OMM (Fonte: WMO, 2021).

De acordo com Bauer et al. (2015), em função desses desenvolvimentos científicos e tecnológicos, houve um importante aumento da acurácia das previsões do tempo nos últimos 40 anos. Por exemplo, a acurácia para previsões de 3 a 10 dias à frente tem aumentado em cerca de um dia por década: uma previsão de horizonte de 6 dias nos dias atuais é tão precisa quanto uma previsão de horizonte de 5 dias, há dez anos (Figura 3.4). Ademais, devido à maior cobertura de informações observacionais em escala global, tem havido uma equiparação da acurácia dessas previsões para os hemisférios Norte e Sul.

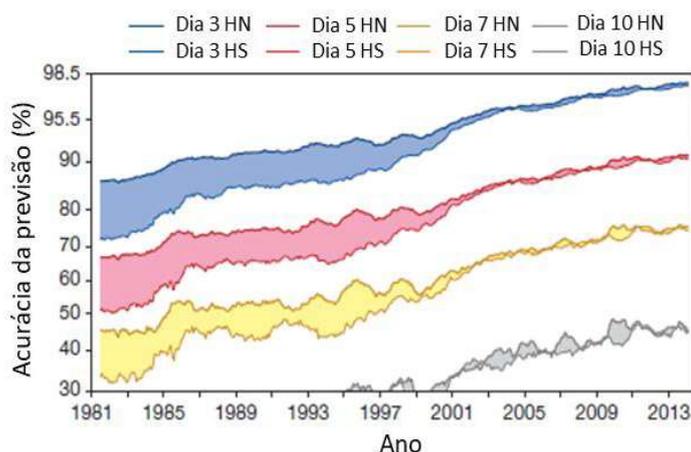


Figura 3.4 - Evolução da acurácia das previsões do tempo de horizontes de 3, 5, 7 e 10 dias, para os hemisférios Norte (HN) e Sul (HS) (Fonte: adaptado de Bauer et al., 2015).

No entanto, apesar desses importantes avanços, ainda existem limitações na previsibilidade meteorológica e na determinação da evolução temporal atmosférica de forma completa, dado o comportamento caótico e a complexidade dos processos que envolvem a circulação geral da atmosfera (SENE, 2010; SILVA et al., 2006).

Essas limitações foram identificadas por Edward Lorenz na década de 1960, por meio de um estudo para entender como a dinâmica atmosférica interna limita a previsibilidade meteorológica. Nesse estudo, Lorenz (1963) descobriu que as equações que descrevem o sistema atmosférico exibem um comportamento caótico, de forma que uma pequena perturbação na condição inicial dessas equações seria capaz de resultar em estados atmosféricos futuros significativamente diferentes. Este efeito, que posteriormente ficou conhecido como "atrator de Lorenz" ou "efeito borboleta", implica que "as previsões determinísticas de eventos atmosféricos para além de alguns dias não são possíveis porque a condição inicial usada para inicializar uma previsão não pode ser certa, independentemente de quão precisas as observações possam estar" (ROUNDY et al., 2019).

Assim, dada a “teoria do caos” introduzida por Lorenz, pequenos erros nas condições iniciais da atmosfera tendem a aumentar rapidamente e se propagar ao longo do horizonte de previsão. Devido a isso, e uma vez que a previsibilidade de curto prazo da atmosfera é influenciada principalmente por suas condições iniciais, as previsões do tempo podem, potencialmente, ser previstas com uma antecedência máxima de até cerca de 15 dias. Ou seja, não é possível se determinar corretamente uma sequência de eventos atmosféricos, dia a dia, para meses ou anos no futuro (ECMWF, 2017; KALNAY, 2003; ROUNDY et al., 2019; SILVA et al., 2006).

Isso não significa, no entanto, que as previsões atmosféricas para além desse horizonte sejam totalmente impossíveis. A incorporação das incertezas nas condições iniciais a partir de técnicas de previsão por conjunto e a evolução dos modelos acoplados oceano-atmosfera têm possibilitado o fornecimento de estimativas probabilísticas dos estados atmosféricos futuros para horizontes superiores a duas semanas (ALLEY et al, 2019; KALNAY, 2003; ROUNDY et al., 2019), conforme será discorrido nos próximos itens deste trabalho.

Neste ponto, faz-se oportuna a distinção entre dois tipos de previsão atmosférica: as *previsões do tempo*, e as *previsões climáticas*.

3.3.3 Previsão do tempo versus previsão climática

Apesar de governados pelas mesmas leis físicas, é importante definir as diferenças entre *tempo* e *clima*. Segundo Rasmusson et al. (1993), tempo é “a condição na atmosfera em um determinado instante”, e clima é “o estado médio da atmosfera durante um período de tempo”, que podem ser semanas, meses, anos ou milênios.

De acordo com os referidos autores, o clima da Terra é determinado pela resposta interativa dos oceanos e da atmosfera, da criosfera (superfície terrestre coberta permanentemente por gelo e neve) e da superfície terrestre e sua biomassa às fontes externas de energia – a radiação solar, majoritariamente, e em menor proporção outras fontes, tais como erupções vulcânicas e mudanças na superfície terrestre. O equilíbrio energético do planeta é mantido pelo transporte de calor por longas distâncias, proveniente da circulação dos oceanos e da atmosfera, e a capacidade térmica dos oceanos é quem fornece o armazenamento sazonal desse calor, que modera as mudanças de temperatura entre o verão e o inverno; caso contrário, essas mudanças seriam muito mais bruscas.

Nesse contexto, as previsões de tempo e de clima se diferenciam no que se refere ao tempo de antecedência dessas previsões. As primeiras são aquelas cujo horizonte previsto vai desde o curtíssimo prazo (antecedências de algumas horas) até o médio prazo, de até duas semanas à frente. Para a obtenção dessas previsões, é avaliada a evolução temporal da atmosfera a partir da resolução numérica das equações que descrevem os processos de circulação, cujas condições iniciais (estado atual da atmosfera) são fornecidas por uma extensa rede de dados observacionais, composta por estações meteorológicas em superfície, balões meteorológicos, aviões, radares, satélites, entre outros (COLLISCHONN, 2001; SILVA et al., 2006).

Já as *previsões climáticas*, ou *previsões sazonais*, que são o foco do presente trabalho, estão relacionadas ao comportamento da atmosfera em um longo prazo de antecedência, geralmente de meses no horizonte. Em geral, estas previsões não buscam determinar com exatidão o momento e o local de ocorrência dos eventos atmosféricos, mas sim representar os valores médios das variáveis meteorológicas (dentre elas, a precipitação) ao longo do horizonte previsto, ou então em termos de anomalias climáticas ou tercis de probabilidade (acima, abaixo ou próximo da média). Estes valores estão mais relacionados a componentes de evolução lenta do sistema climático, tais como a Temperatura da Superfície do Mar (TSM), a criosfera e a umidade do solo. Dessa forma, as previsões sazonais baseiam-se na modelagem da evolução dos fenômenos climáticos de grande escala, na qual os oceanos normalmente representam a memória do sistema, uma vez que são mais “inertes” por possuírem capacidade térmica muito maior do que a atmosfera (ECMWF, 2017; QUEDI, 2019; RASMUSSEN et al., 1993; SILVA et al., 2006; TROCCOLI et al., 2008).

A integração das escalas temporais das previsões de tempo e climáticas tem sido objeto de grande dedicação por parte dos centros de meteorologia, havendo assim um rápido progresso nas chamadas previsões de escala de tempo *sub-sazonal*, cujos horizontes geralmente variam de duas semanas a dois meses (ALLEY et al., 2019; QUEDI, 2019; VITART et al., 2012). Esse progresso teve como principal propulsor o *Sub-Seasonal to Seasonal Prediction Project (S2S)*, um projeto que teve por objetivo melhorar a precisão dessas previsões e a compreensão das fontes de previsibilidade sub-sazonal a sazonal, além de promover sua adoção por centros operacionais de meteorologia (VITART e ROBERTSON, 2018). Nesse contexto, centros como o ECMWF, o NWS/NOAA, CPTEC, entre outros, têm realizado previsões sub-sazonais por meio de sistemas que combinam características da previsão de tempo e da previsão climática (NASEM, 2016; SILVA et al, 2006).

3.3.4 Modelos acoplados de circulação geral (CGCMs)

Historicamente, a principal (e mais simples) forma de obterem previsões sazonais era por meio de abordagens estatísticas, desenvolvendo-se, por exemplo, correlações entre a resposta, ou variável dependente, (e.g. temperatura, precipitação acumulada) e os índices atmosféricos e/ou oceânicos que se acredita serem a influência principal (preditores ou variáveis independentes) – correlações estas comumente chamadas de *teleconexões*. Essas técnicas de previsão ainda são bastante úteis e possuem um importante papel, particularmente para regiões onde há fortes correlações entre causa e efeito. No entanto, uma limitação dessa metodologia é a suposição de que os dados históricos são representativos das condições futuras, o que nem sempre é o caso devido às variações climáticas e outros fatores (SENE, 2010; TROCCOLI et al., 2008).

Com os avanços na meteorologia e na aquisição de dados atmosféricos e oceânicos, assim como ao uso de supercomputadores para avaliação da circulação atmosférica global, as previsões sazonais passaram também a ser determinadas a partir de modelos dinâmicos complexos, conhecidos como modelos acoplados de circulação geral atmosfera-oceano-terra, ou CGCMs (*Coupled atmosphere-ocean-land General Circulation Models*) (NASEM, 2016; TROCCOLI et al., 2008; YUAN et al., 2015). Isso permitiu um maior entendimento da evolução e caracterização dos padrões climáticos de grande escala a partir de indicadores de TSM, como o El Niño-Oscilação Sul, ou ENSO (*El Niño-Southern Oscillation*); a Oscilação Decadal do Pacífico, ou PDO (*Pacific Decadal Oscillation*); a Oscilação do Atlântico Norte, ou NAO (*North Atlantic Oscillation*); e o Dipolo do Oceano Índico, ou IOD (*Indian Ocean Dipole*) (ARNAL et al., 2018; BROWNING, 2003; COLLIER e KZYYSZTOFOWICZ, 2000; YUAN et al., 2015).

Índices climáticos diferentes possuem contribuições diferentes para regiões diferentes. No entanto, o ENSO tem sido considerado a maior fonte de previsibilidade climática sazonal e, por isso, muitas pesquisas sobre previsões de longo prazo têm se concentrado em sua determinação, dado que sua influência pode se estender por quase todas as partes do globo (YUAN et al., 2015). De acordo com estes autores, a incorporação do ENSO aumenta consistentemente a acurácia das previsões nas regiões da América do Sul equatorial e do sudeste da Ásia.

O fenômeno El Niño – a fase positiva (quente) do ENSO – está associado a aumentos anormais (além das variações normais) da TSM no Oceano Pacífico oriental e central, durante períodos característicos de 2 a 7 anos e durações típicas de alguns meses ou mais, e está vinculado a

variações nas circulações de superfície e subsuperfície no Oceano Pacífico. Episódios de El Niño tendem a se alternar com episódios de resfriamento da TSM (La Niña) e provocam variações na pressão atmosférica global, ou Oscilação Sul, levando ao termo amplamente utilizado *El Niño-Oscilação Sul*. Os eventos ENSO, em particular, possuem forte influência nas temperaturas e pressões ao nível do mar e nas chuvas tropicais, bem como na corrente de jato do hemisfério norte e na Oscilação Madden Julian (OMJ) (SENE, 2010; TROCCOLI et al., 2008).

Os impactos climáticos dos fenômenos El Niño e La Niña ao longo do globo terrestre podem ser visualizados na Figura 3.5 e Figura 3.6, respectivamente.

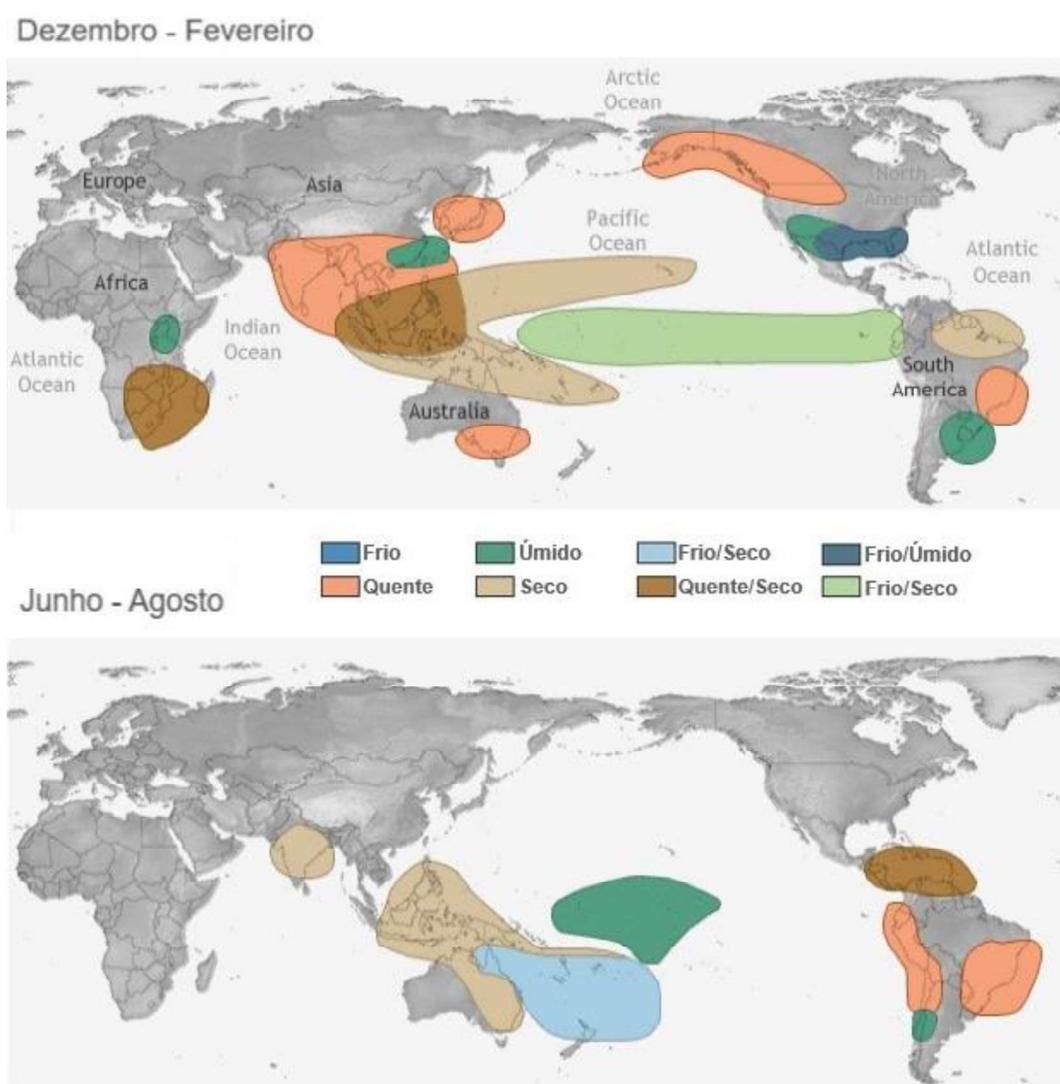


Figura 3.5 - Impactos climáticos do fenômeno El Niño ao longo do globo terrestre (Fonte: adaptado de NOAA Climate.gov, 2021).

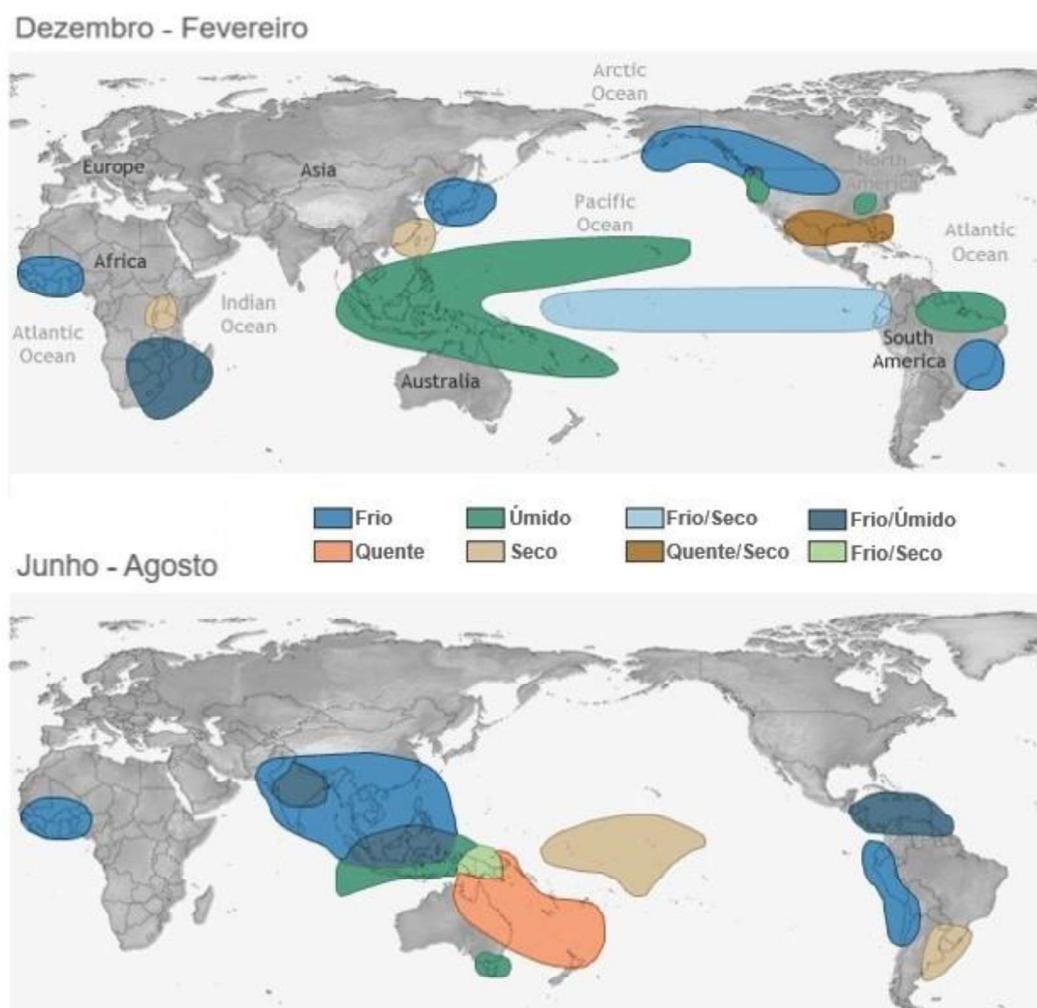


Figura 3.6 - Impactos climáticos do fenômeno La Niña ao longo do globo terrestre (Fonte: adaptado de NOAA Climate.gov, 2021).

Em função desses impactos em escala global, desde o início do desenvolvimento dos CGCMs tais modelos foram direcionados à simulação e previsão do ENSO, assim como das mudanças climáticas em uma escala de tempo sazonal. Para a inicialização desses modelos acoplados é necessário, portanto, conhecer o estado atual do sistema que se está tentando prever, ou seja, as condições iniciais da atmosfera, da superfície terrestre e do oceano, sendo estas as mais importantes para as previsões de horizontes de longo prazo (TROCCOLI et al., 2008).

A inicialização do componente oceânico do CGCMs é feita a partir de dados de satélite, boias meteoceanográficas (medição de ondas), entre outros. No entanto, um problema geral para a assimilação desses dados é que estes são relativamente escassos, em comparação com os disponíveis para as superfícies terrestres. Em função dessas incertezas acerca das condições iniciais do modelo, as previsões de longo prazo são normalmente emitidas em termos

probabilísticos, como valores médios em períodos de um mês ou mais, e as execuções do modelo só podem ser realizadas semanalmente ou com menor frequência (SENE, 2010; TROCCOLI et al., 2008).

De acordo com Zhao et al. (2017), atualmente os CGCMs são considerados o estado da arte para previsão das condições atmosféricas e oceânicas em horizontes sazonais, uma vez que eles têm apresentado acurácia semelhante ou superior aos métodos estatísticos para previsão climática. Em função disso, estes últimos têm sido substituídos pelas previsões climáticas por conjunto dos CGCMs em muitos serviços meteorológicos nacionais. Por exemplo, o NCEP/NOAA nos Estados Unidos, que opera seu *Climate Forecast System* (CFS) desde 2004, o qual atualmente se encontra em sua segunda versão (SAHA et al., 2014); o ECMWF, que opera seu *Seasonal Forecast System* desde 1997, o qual atualmente se encontra em sua quinta versão (ECMWF, 2017; JOHNSON et al., 2019); e o CPTEC/INPE no Brasil, que opera o seu modelo CPTEC/COLA desde 1995 (CAVALCANTI et al., 2002).

3.3.5 Uso das previsões climáticas em aplicações hidrológicas

Até alguns anos atrás, as previsões hidrológicas de longo prazo eram tão incertas que a vazão futura raramente era utilizada como dado de entrada para o planejamento da operação de reservatórios (GALVÃO, 1999). Para fins práticos, essas previsões só eram confiáveis quando a vazão futura possuía maior dependência da água armazenada na bacia no momento da previsão do que das condições meteorológicas futuras. Isso porque as previsões climáticas, com antecedências de alguns meses, possuíam um nível de precisão tão pequeno que não agregavam melhorias na previsão hidrológica (CASSARDO, 2009; LETTENMAIER e WOOD, 1993; QUEDI, 2019).

No entanto, devido à evolução dos modelos meteorológicos e ao maior entendimento das conexões entre os fenômenos climáticos de grande escala e os eventos hidrológicos, o uso das previsões climáticas foi ganhando espaço na previsão hidrológica. Isso se deve não apenas ao aumento da acurácia dessas previsões, como também à tendência de aproximação de suas resoluções espaciais das escalas de interesse em previsões hidrológicas operacionais. Dessa forma, as possibilidades de uso das previsões climáticas têm sido largamente ampliadas, assim como o seu uso nas previsões hidrológicas de longo prazo, especialmente em grandes bacias (COLLISCHONN, 2001; ROUNDY et al., 2019; SENE, 2010; SILVA et al., 2006).

Por outro lado, para bacias de menor escala esse uso ainda é limitado, uma vez que a resolução espacial das previsões climáticas ainda é mais grosseira (geralmente da ordem de dezenas a centenas de quilômetros) do que a escala dessas bacias, sendo, portanto, insuficiente para resolver importantes características de escalas regionais (e.g. a topografia local) e, conseqüentemente, fenômenos meteorológicos de menor escala (COLLISCHONN, 2001; FLATO et al., 2013; QUEDI, 2019; TUCCI et al., 2003; YUAN et al., 2015). Para solucionar essa incompatibilidade, faz-se necessária a aplicação de alguma técnica de pós-processamento, como por exemplo o *downscaling*, que busca relacionar variáveis preditoras atmosféricas de grande escala com séries meteorológicas em escala regional ou de estação. Maiores detalhes sobre essa técnica podem ser encontrados nos trabalhos de Flato et al. (2013), Trzaska e Schnarr (2014), Xu (1999) e Xue et al. (2014).

Trabalhos como os de Galvão (1999), Wood et al. (2002), Tucci et al. (2003) e Li et al. (2008), avaliaram o uso das previsões climáticas para previsão hidrológica em diferentes bacias. Nestes trabalhos, os autores expõem a potencialidade desse uso para indicação das perspectivas hidrológicas para os próximos meses e, assim, para o planejamento de sistemas de recursos hídricos, mas evidenciam as limitações acerca das previsões climáticas, dados que estas muitas vezes apresentam vieses para algumas regiões do globo.

De fato, Troccoli et al. (2008) afirmam que as previsões brutas dos CGCMs não são capazes de representar o clima com precisão para todas as regiões e circunstâncias, sendo normalmente necessário um pós-processamento dessas previsões antes de utilizá-las na prática (e.g. em modelos hidrológicos), de modo a se removerem possíveis erros sistemáticos (ou vieses). Em função disso, é comum as previsões climáticas serem geradas juntamente com os chamados *hindcasts* ou *re-forecasts*, que são “previsões” retrospectivas para anos anteriores, geralmente de 15 a 25 anos.

Dessa forma, para um determinado mês, para cada um desses anos, é feito um conjunto de previsões, de forma a se definir a climatologia do modelo para aquele mês. A comparação desta com a climatologia observacional da região modelada permite a detecção e correção de possíveis vieses da previsão climática, por exemplo, a partir de uma correção linear de primeira ordem para o erro do modelo (TROCCOLI et al., 2008). Existem ainda outras técnicas estatísticas de remoção de viés mais elaboradas, tais como *Quantile Mapping* (CANNON et al., 2015), modelagem de probabilidade conjunta Bayesiana (WANG et al., 2009), entre outras.

Ademais, um aspecto importante na utilização de previsões climáticas para previsão de vazões é a consideração das incertezas a elas associadas, dado seu caráter caótico e não linear e de sua forte dependência de suas condições iniciais (COLLISCHONN, 2001; GALVÃO, 1999; TUCCI et al., 2003). Desse modo, o tratamento das previsões hidrológicas de longo prazo deve se dar em termos probabilísticos, tal como será discutido nos próximos itens deste documento.

3.4 Previsão hidrológica e suas incertezas

As incertezas associadas à previsão hidrológica ainda são consideradas como um dos vinte e três principais problemas científicos não resolvidos da Hidrologia, identificados pela ampla comunidade hidrológica por iniciativa da Associação Internacional de Ciências Hidrológicas, ou IAHS (*International Association of Hydrological Sciences*) (BLÖSCHL et al., 2019). Segundo tal iniciativa, apesar do grande progresso desenvolvido ao longo das últimas quatro décadas em termos de método e consciência, ainda há muito trabalho a ser feito no que diz respeito a esse tema.

As fontes dessas incertezas podem ser várias, e normalmente dependem do evento a ser previsto e do método de previsão. Em geral, tais fontes de incertezas podem ser resumidas em: (i) aleatoriedade inerente aos processos hidrometeorológicos; (ii) dados de entrada ao modelo; (iii) estrutura do modelo e sua incapacidade de representar exatamente o real comportamento do sistema; e (iv) parâmetros do modelo (FAN, 2015; KRZYSZTOFOWICZ, 2001; MONTANARI, 2011; NETO, 2013; XAVIER, 2002). Dentre os dados de entrada do modelo estão as previsões numéricas de precipitação, que são a fonte predominante de incerteza em uma previsão hidrológica (BROWNING, 2003; KRZYSZTOFOWICZ, 2001),

Nesse contexto, Todini (2007) afirma que as incertezas desempenham um papel cada vez maior na modelagem e previsão hidrológicas, mas que ainda não há um consenso entre os hidrólogos em sua avaliação, em razão da complexidade estatística para a determinação dessas incertezas e pelo fato de os usuários finais muitas vezes não saberem como interpretar e utilizar esse tipo de informação na tomada de decisão. Segundo o autor, a forma mais abrangente de se lidar com quantidades incertas é por meio de suas distribuições de probabilidade, em lugar da estimação apenas de seus valores esperados.

Krzysztofowicz (2001) ressalta, ainda, que as previsões de vazão devem ser declaradas em termos probabilísticos ao invés de determinísticos, a fim de se quantificarem suas incertezas preditivas e serem fornecidas informações de forma mais completa e cientificamente mais honestas. Isso permite ao usuário final uma melhor avaliação das escolhas na tomada de decisões e do gerenciamento de riscos (SENE, 2010; ZHANG et al., 2020). Um exemplo de formato de apresentação de previsão probabilística encontra-se ilustrado na Figura 3.7.

Apesar disso, o formato predominante das previsões hidrológicas operacionais ainda é determinístico, o que força o previsor a suprimir informações e julgamentos sobre a incerteza preditiva. Isso acaba criando a falsa ilusão de certeza ao usuário final da informação, o que pode fazer com que este tome uma decisão que não seja a mais ideal (KRZYSZTOFOWICZ, 2001).

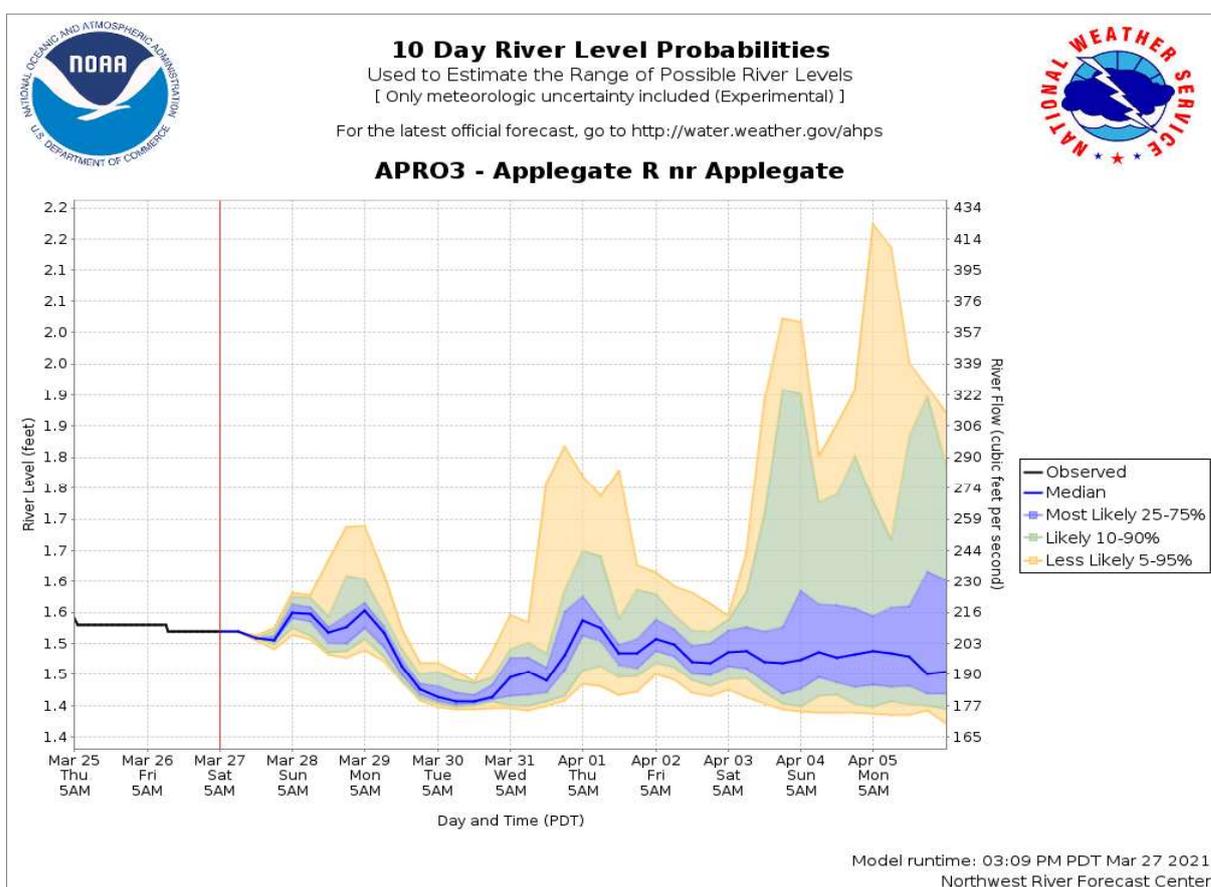


Figura 3.7 – Exemplo ilustrativo de previsão hidrológica probabilística
 (Fonte: NWS/NOAA, 2021a).

3.4.1 Incertezas associadas à previsão de precipitação

Em função da grande variabilidade de estado e à natureza caótica e não-linear da atmosfera, na Meteorologia tem sido amplamente utilizado o conceito de previsão probabilística por conjunto, ou *previsão por ensemble*, de forma a se incorporarem as incertezas associadas às condições de inicialização dos modelos meteorológicos e se determinarem as probabilidades de estados atmosféricos futuros (FAN, 2015; KALNAY, 2003; KRZYSZTOFOWICZ, 2001; NASEM, 2016; ROUNDY et al., 2019). Assim, (i) a partir de diferentes condições iniciais de um modelo, ou (ii) a partir de diferentes modelos meteorológicos, são gerados diferentes cenários equiprováveis de precipitação, denominados *membros*, que representam as possíveis trajetórias dos processos atmosféricos ao longo do horizonte de previsão.

No primeiro caso, um mesmo modelo meteorológico é simulado a partir de diferentes condições iniciais, seja perturbando o estresse do vento e a TSM, por exemplo, ou simulando o modelo com diferentes datas de início, ou seja, defasando o *ensemble* no tempo (YUAN et al., 2015). Ao conjunto de possíveis trajetórias geradas por essas perturbações, também conhecido como “espaguete”, pode-se associar uma distribuição de probabilidade (Figura 3.8), a qual pode ser entendida como uma tradução das incertezas associadas àquela previsão (FAN, 2015; QUEDI, 2019).

Uma outra forma de previsão por conjunto é a denominada *previsão por ensemble multimodel*, ou MME (*Multi-Model Ensemble*). O MME é resultante da utilização de diferentes modelos meteorológicos, cada qual com suas equações físicas e parametrizações, para representar os possíveis cenários para o estado futuro da atmosfera e, assim, permitir a avaliação das incertezas associadas à previsão. Segundo Yuan et al. (2015), a utilização de diferentes modelos meteorológicos, desenvolvidos por distintos centros operacionais de meteorologia ao longo do globo, resulta em previsões mais confiáveis e acuradas, uma vez que a independência entre esses modelos permite a geração de previsões que são complementares. Nesse sentido, os autores enfatizam que o uso de produtos de vários projetos de *ensemble multimodel* nas últimas décadas, tais como o projeto DEMETER (*Development of a European Multimodel Ensemble system for seasonal to inTERannual prediction*) (PALMER et al., 2004) e o NMME (*North American Multimodel Ensemble*) (KIRTMAN et al., 2014), tem sido muito bem sucedido para melhorar as previsões hidrológicas sazonais em bacias de escalas continental e global.

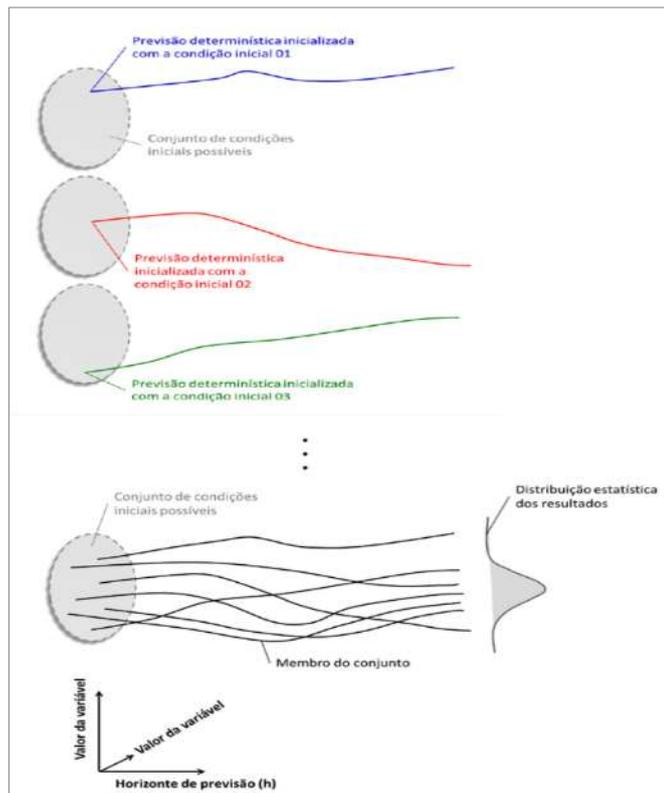


Figura 3.8 - Representação de uma previsão por *ensemble* obtida a partir de perturbações nas condições de inicialização do modelo meteorológico (Fonte: adaptado de Fan, 2015).

O primeiro uso operacional de previsões por *ensemble* começou no *United Kingdom Meteorological Office (Met Office)*, em dezembro de 1988 (GOLDING et al, 2006; WMO, 2000). Desde a sua introdução, o princípio da previsão por conjunto foi adaptado para intervalos de tempo mais curtos e, após uma série de pesquisas sobre como perturbar as condições iniciais de forma mais eficaz, a previsão do conjunto foi implementada operacionalmente no NCEP e no ECMWF em 1992 (BARKMEIJER et al., 2012; KALNAY, 2003). Atualmente, as previsões por *ensemble* formam a base das previsões meteorológicas, permitindo a identificação do resultado mais provável, sua incerteza e cenários alternativos (GOLDING et al, 2006).

Mais recentemente, esse emprego de previsões por conjunto para incorporação de incertezas vem sendo adotado também na Hidrologia, principalmente por meio da associação das previsões meteorológicas por *ensemble* a um modelo hidrológico tipo chuva-vazão para obter, da mesma maneira, um *ensemble* de previsões de vazão, ou ESP (*Ensemble Streamflow Prediction*) (COLLISCHONN, 2001; CLOKE e PAPPENBERGER, 2009; FAN, 2015; QUEDI, 2019; ZHANG et al., 2020). Essa associação constitui, portanto, em um Sistema de Previsão Hidrológica por Conjunto, ou H-ESP (*Hydrologic Ensemble Prediction System*), o

qual permite a obtenção de diferentes cenários futuros de vazões para horizontes além do tempo de concentração da bacia. Um exemplo ilustrativo de ESP pode ser visualizado na Figura 3.9.

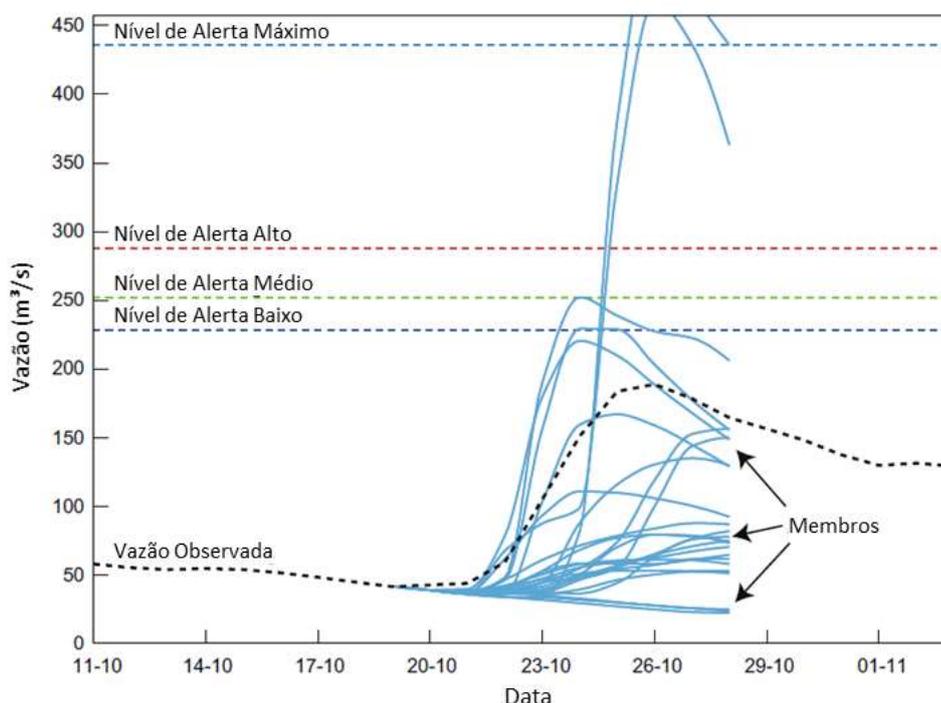


Figura 3.9 - Exemplo ilustrativo de um ESP para um evento de inundação (Fonte: adaptado de Cloke e Pappenberger, 2009).

A previsão probabilística de vazões é uma área de pesquisa bastante ativa dentro dos serviços hidrológicos de vários países, e é uma das principais áreas de interesse dentro do HEPEX (*The Hydrologic Ensemble Prediction Experiment*), um projeto internacional que envolve pesquisadores do *National Weather Service* dos Estados Unidos, do ECMWF, do *European Joint Research Centre*, e do Canadá, Itália, Brasil e outros países (SCHAAKE et al., 2007).

As vantagens acerca do uso de previsões por *ensemble* em relação às previsões determinísticas, segundo WMO (2000), são que, (i) em geral, a média do *ensemble* fornece uma previsão melhor do que qualquer membro individual do conjunto, e que (ii) a dispersão dos membros do *ensemble* fornece um indicativo da confiabilidade da previsão, de forma que uma menor dispersão indica sensibilidade limitada a erros nas condições iniciais e, portanto, maior confiabilidade na previsão.

Dessa forma, as previsões por conjunto permitem uma interpretação mais ampla dos resultados, uma vez que fornecem ao usuário uma faixa dos possíveis valores de previsão. Isso permite se fazerem inferências sobre quais são as trajetórias mais prováveis da variável, com base na maior concentração dos membros, e conhecer o nível de previsibilidade por meio do espalhamento dos membros do *ensemble*, por exemplo. Com isso, pode-se ter um melhor entendimento das incertezas associadas às previsões e, assim, um maior embasamento para as decisões operacionais diante dos possíveis cenários hidrológicos futuros (FAN, 2015; QUEDI, 2019).

3.4.2 Incertezas associadas à modelagem hidrológica

Conforme discorrido anteriormente, a principal fonte de incerteza das previsões hidrológicas está relacionada à precipitação futura, e o uso de previsões por *ensemble* permite incorporar essas incertezas às vazões previstas. No entanto, existem uma série de outras incertezas que permeiam as previsões hidrológicas, e muitas delas estão associadas à própria modelagem hidrológica em si.

Segundo Vrugt e Massoud (2019), as fontes mais importantes de incerteza na modelagem de sistemas ambientais estão relacionadas: (1) aos parâmetro do modelo; (2) aos dados de entrada (também chamados de “forçantes”); (3) ao estado inicial do modelo (variáveis de estado); (4) à estrutura do modelo (erros epistêmicos); (5) às saídas do modelo; e (6) às incertezas dos dados de calibração, conforme esquematizado na Figura 3.10.

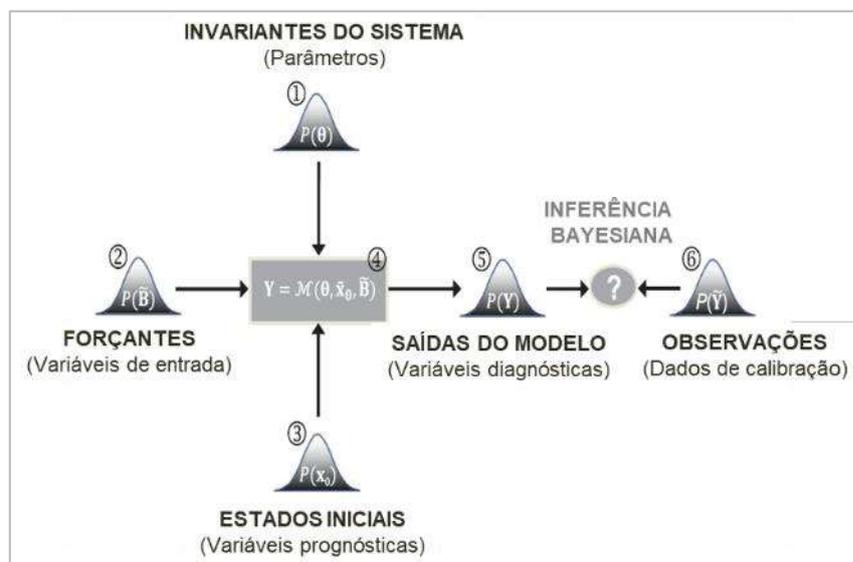


Figura 3.10 - Incertezas associadas à modelagem hidrológica (Fonte: adaptado de Vrugt e Massoud, 2019).

Dessa forma, um processo de modelagem hidrológica típico envolve a comparação dos dados observados, aos quais estão associadas suas devidas incertezas de medição, com as vazões simuladas por um modelo imperfeito, com suas próprias incertezas estruturais, paramétricas e de medição. Com isso, as incertezas associadas a cada uma dessas fontes acabam sendo propagadas através da estrutura do modelo, o que torna bastante complexa a desagregação e a modelagem dos erros observacionais (diferenças entre as variáveis observadas e simuladas) por um modelo estatístico (CHO et al., 2019).

No presente trabalho, além das incertezas associada às previsões numéricas de precipitação anteriormente discutidas, procurou-se tratar também das incertezas associadas aos parâmetros (calibração) do modelo hidrológico e às suas variáveis de estado. Os próximos itens deste documento tratam da estimação de incertezas paramétricas do modelo, e o método que foi aplicado na pesquisa. Com relação ao tratamento das incertezas dos estados do modelo, foi aplicada uma metodologia que se encontra descrita no Capítulo 4 - MATERIAL E MÉTODOS deste documento.

3.4.2.1 Incertezas paramétricas dos modelos

Usualmente, a calibração dos modelos hidrológicos é feita de maneira determinística, buscando-se encontrar um conjunto de parâmetros ótimo a partir de uma dada função objetivo, na tentativa de se obterem os menores desvios possíveis entre as grandezas simuladas e observadas. Nesse sentido, houve um intenso progresso no desenvolvimento e aplicação de procedimentos automatizados para calibração de modelos hidrológicos, na tentativa de se minimizar uma medida de verossimilhança da variância geral (estatística) dos resíduos desses modelos (VRUGT et al., 2008).

Apesar de sua aplicação extensiva, a calibração parametrizada tem como principal fraqueza o fato de assumir que todas as fontes de incerteza são atribuídas a erros de parâmetros. Isso geralmente resulta em estimativas viesadas de parâmetros que compensam os outros tipos de incerteza inerentes à modelagem hidrológica, comprometendo a capacidade preditiva do modelo (ROJAS et al., 2008).

Segundo Collischonn (2001), a experiência com os modelos hidrológicos, sejam eles concentrados ou distribuídos, comprova que “nenhuma técnica de calibração e nenhum modelo atingem uma perfeita concordância entre os valores calculados e observados”, em função das

inúmeras incertezas associadas à modelagem hidrológica. Ademais, Montanari (2011) afirma que, em geral, os parâmetros desses modelos não são independentes, existindo uma alta interação ou correlação entre os mesmos. Isso acaba tornando a calibração do modelo incerta, uma vez que as simulações resultantes serão função da interação desses parâmetros, e não de cada um deles individualmente.

Além disso, deve-se ter em mente que existem também incertezas associadas aos dados observados utilizados como balizadores da calibração, e também à própria estrutura do modelo hidrológico e sua incapacidade em reproduzir precisamente a física dos processos hidrológicos (BEVEN e BINLEY, 1992; COLLISCHONN, 2001; MONTANARI, 2011; NETO, 2013; XAVIER, 2002).

Com base nessas ressalvas, Beven (1993) introduz então o conceito de *equifinalidade*, a partir do qual se rejeita a hipótese de um conjunto paramétrico ótimo e assume-se a existência de mais de um conjunto de parâmetros capazes de reproduzir o comportamento da bacia de forma satisfatória. O autor afirma que isso não significa dizer que as simulações a partir desses conjuntos são equiprováveis, mas sim que cada uma dessas simulações pode ser aceitável como resposta do sistema e pode ser classificada em termos de desempenho ou probabilidade, dado algum critério de avaliação. Assim, a existência de mais de um conjunto de parâmetros possível é um indicativo da incerteza inerente aos modelos hidrológicos quanto à interação de seus parâmetros e de sua capacidade em reproduzir dos processos hidrológicos do sistema.

3.4.2.2 Abordagem Bayesiana para inferência de parâmetros

Ao longo dos últimos anos, surgiu na literatura uma série de métodos para o tratamento e a determinação das várias fontes de incerteza associadas à modelagem hidrológica anteriormente discutidas. Dentre eles encontram abordagens Bayesianas e pseudo-Bayesianas para inferência de parâmetros, que permitem o fornecimento de valores mais prováveis das previsões, juntamente com estimativas das faixas de resultados possíveis (VRUGT et al., 2008).

Segundo Sene (2010), essas técnicas se mostram promissoras no fornecimento de uma estrutura de previsão geral incorporando assimilação de dados e estimação de incertezas, com o objetivo de se inferir a incerteza preditiva condicionada a todas as informações disponíveis no momento da previsão, tais como dados observacionais, desempenho do modelo em intervalos de tempo anteriores ao da previsão (simulação), entre outras.

Ao contrário da inferência de parâmetros a partir da calibração determinística, na qual o parâmetro é visto como um valor fixo e único, na inferência Bayesiana os parâmetros de um modelo são vistos como valor fixo mas, por serem desconhecidos, são aleatórios. Devido a isso, estão associados a uma distribuição de probabilidades, a qual reflete a incerteza do conhecimento a priori acerca desses parâmetros. Na abordagem Bayesiana, acredita-se haver um valor verdadeiro para o parâmetro, cuja estimativa pontual pode ser obtida a partir de sua correspondente distribuição a posteriori. Assim, à medida em que se aumenta o conhecimento sobre esse parâmetro, espera-se que diminua a incerteza acerca dele (FERNANDES, 2009; FERNANDES et al., 2010; SILVA et al., 2014).

Uma forma de se avaliarem as incertezas em modelos hidrológicos sob o paradigma Bayesiano é a partir de métodos de simulação de Monte Carlo (MC), que consistem em métodos de amostragem extremamente flexíveis e robustos. Nessas simulações, valores aleatórios de cada parâmetro θ são amostrados de suas respectivas distribuições de probabilidade (ou função densidade de probabilidade – FDP) a priori, obtendo-se, assim, múltiplas realizações dos resultados do modelo (e. g. vazão simulada a partir de cada conjunto de parâmetros θ_i). A correlação dessas realizações com as observações do fenômeno modelado (e.g. vazão observada) é analisada a partir de algum critério de avaliação de similaridade, geralmente uma função de verossimilhança. Assim, é possível sintetizar, a partir de métricas estatísticas e de distribuições de probabilidades empíricas, obtidas a posteriori, o comportamento exibido pelos parâmetros e pelo resultado do modelo (SHRESTHA, 2009; SILVA et al., 2014; SILVA, 2015). Uma representação esquemática dessa metodologia encontra-se ilustrada na Figura 3.11.

Nos últimos anos, houve na comunidade científica um intenso debate acerca do uso de uma abordagem formal ou informal para especificar a função de verossimilhança (MANTOVAN e TODINI, 2006; BEVEN et al., 2008; VRUGT et al., 2008; STEDINGER et al., 2008), que se distinguem quanto ao rigor estatístico admitido em sua concepção. Na abordagem Bayesiana formal assume-se, de maneira explícita, uma distribuição probabilística a priori para os erros residuais r , a qual pode ser posteriormente validada (por exemplo, assumindo $r \sim N(0, \sigma)$ (resíduos gaussianos), resulta-se na abordagem dos mínimos quadrados padrão (SLS – *Standard Least Squares*) para estimativa de parâmetro). Já na abordagem informal (pseudo-Bayesiana), não há referência direta a um modelo probabilístico para os resíduos (e.g. critério de Nash-Sutcliffe), de forma que essa validação não pode ser procedida a posteriori (SCHOUPS e VRUGT, 2010; SILVA, 2015).

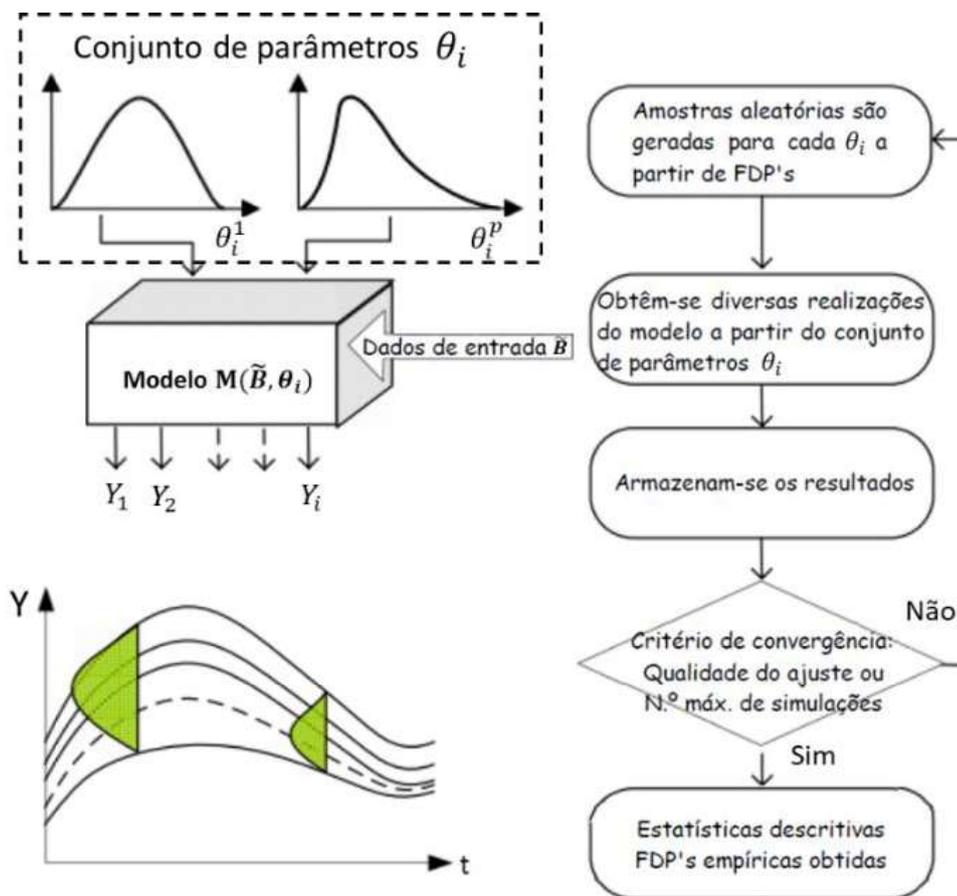


Figura 3.11 - Esquema representativo da simulação de Monte Carlo para análise de incertezas (Fonte: adaptado de Silva, 2015).

De acordo com Schoups e Vrugt (2010), a abordagem formal foi criticada por confiar muito em suposições para o erro residual que não são válidas em muitas aplicações. Em muitas aplicações hidrológicas, os erros residuais são correlacionados, não homocedásticos (variâncias afetadas pela magnitude das vazões simuladas) e não gaussianos (SILVA et al., 2014; SILVA, 2015), e a violação dos pressupostos do SLS pode introduzir distorções nos valores dos parâmetros estimados e afetar o parâmetro e a incerteza preditiva. Desse modo, de maneira alternativa, foram propostas funções de verossimilhança informais como uma abordagem pragmática para estimação de incertezas na presença de estruturas de erro residual complexas. Um exemplo bastante conhecido é o método GLUE, apresentado no item a seguir.

3.4.2.3 O método GLUE

Uma metodologia de abordagem Bayesiana informal para análise de incertezas e baseada no princípio da equifinalidade é o método GLUE (*Generalized Likelihood Uncertainty Estimation*), proposto por Beven e Binley (1992). Este método se baseia em um grande número de simulações do modelo hidrológico a partir da amostragem aleatória do espaço paramétrico, geralmente realizada por meio de simulações de Monte Carlo. A partir destas procura-se eleger, dado um limiar pré-determinado para a medida de verossimilhança, aqueles conjuntos de parâmetros que sejam “comportamentais”, ou seja, que permitam reproduzir as grandezas observadas. A cada um desses conjuntos de parâmetros são associadas probabilidades (pesos), que refletem o grau de incerteza acerca daquele conjunto de acordo com o desempenho da vazão por ele simulada. Tais probabilidades podem ser combinadas e atualizadas usando o teorema de Bayes, podendo então ser usadas como funções de ponderação para estimar a incerteza preditiva do modelo. Assim, à medida que se disponha de novos dados observados, pode ser feita a atualização dessas probabilidades, para que as estimativas de incerteza sejam progressivamente refinadas ao longo do tempo (BEVEN e BINLEY, 1992; CHO et al., 2019; MONTANARI, 2011; NETO, 2013; ROJAS et al., 2008; XAVIER, 2002).

O método GLUE pode ser resumido nas seguintes etapas, as quais se encontram esquematizadas na Figura 3.12: (i) decidir qual(is) estrutura(s) de modelos a ser(em) utilizada(s); (ii) através do método MC, amostrar conjuntos de parâmetros a partir de suas distribuições, definidas a priori; (iii) analisar o ajuste de cada simulação obtida a partir desses conjuntos à série de dados observados, por meio de uma medida de verossimilhança (análise de desempenho); (iv) estabelecer um limiar para essa medida de verossimilhança, de modo a separar os conjuntos de parâmetros considerados “comportamentais” dos “não-comportamentais”; (v) aos conjuntos tidos como “comportamentais”, normalizar os valores das medidas de verossimilhança, que passarão a funcionar como pesos; àqueles conjuntos que forem rejeitados (não comportamentais), serão atribuídos pesos iguais a zero; (vi) os pesos definidos para cada conjunto de parâmetros serão então utilizados para a construção de funções de probabilidade a posteriori, podendo-se assim traçar limites de confiança para as simulações. Esses mesmos pesos são utilizados para a ponderação das simulações futuras, refletindo, portanto, as suas incertezas preditivas (JENSEN, 2003; NETO, 2013; YANG et al., 2008).

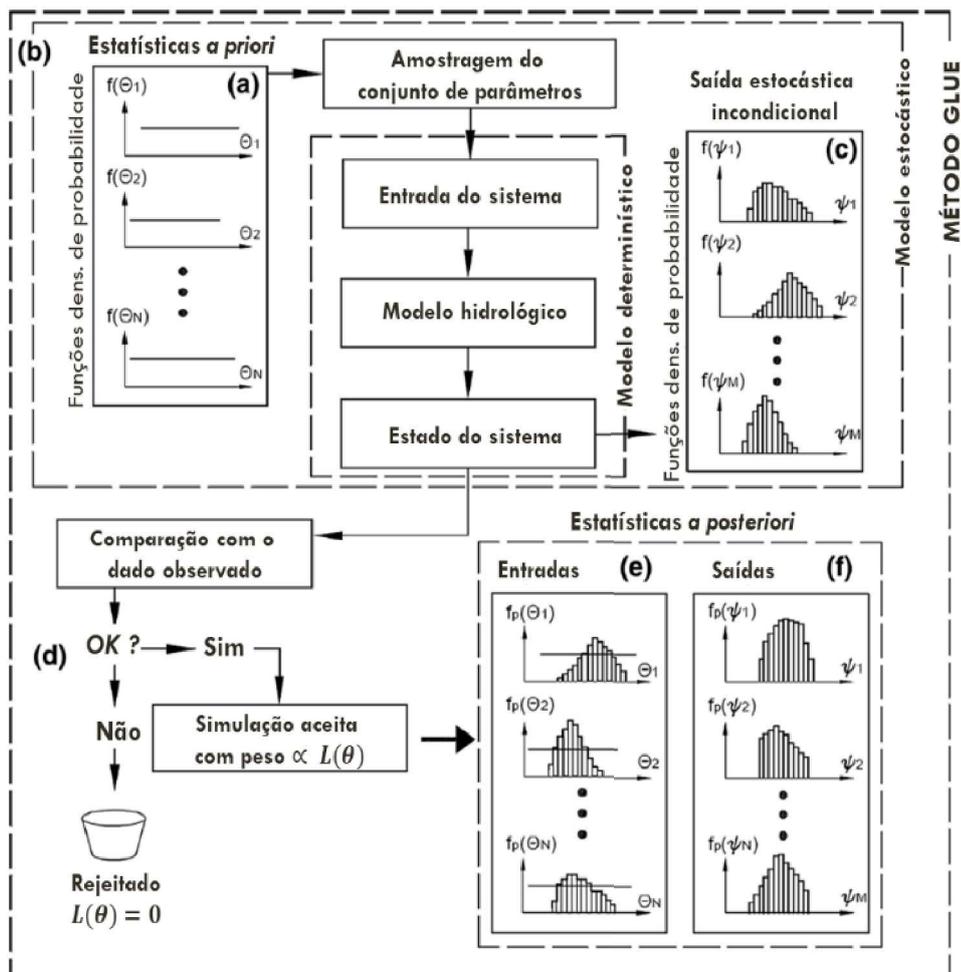


Figura 3.12 - Esquema representativo das etapas da metodologia GLUE (Fonte: adaptado de Jensen, 2003).

De acordo com Beven e Binley (1992), na metodologia GLUE qualquer interação entre os parâmetros não apresenta um problema, uma vez que a mesma será implicitamente refletida nos valores de probabilidade daquele conjunto de parâmetros. Dessa mesma maneira, é possível avaliar conjuntos diferentes de condições iniciais e de contorno, ou seja, diferentes estruturas de modelo podem ser consideradas.

Além disso, Jin et al. (2010) afirmam que o GLUE, quando comparado a outros métodos de estimação de incertezas paramétricas, é bastante simples e de fácil implementação, uma vez que não necessita que sejam feitas alterações nos códigos-fonte dos modelos de simulação. Ademais, possui uma abordagem diferente dos outros métodos, uma vez que não requer suposições estatísticas sobre os erros observacionais (CHO et al., 2019).

Por outro lado, muitas controvérsias a respeito do método GLUE têm surgido pelo fato de ele não ser formalmente Bayesiano e por exigir decisões subjetivas quanto à medida de verossimilhança e ao seu limite de corte para separar os conjuntos de parâmetros comportamentais de não comportamentais, e por não implementar um modelo de erro estatisticamente consistente (JIN et al., 2010; STEDINGER et al., 2008). Além disso, Montanari (2007) ressalta que a formulação clássica do GLUE não leva em consideração o último erro da previsão, uma informação prévia muito importante na previsão em tempo real, dado que os erros dos modelos hidrológicos são, em geral, significativamente correlacionados.

Apesar das limitações supracitadas, devido à simplicidade do método e por não exigir a implementação a priori de um modelo para erros observacionais, o GLUE foi utilizado no presente trabalho para a estimação e incorporação das incertezas paramétricas e preditivas do modelo hidrológico SMAP na determinação das vazões afluentes ao reservatório da UHE Itaipu. Complementarmente, tendo-se em vista a ressalva apontada por Montanari (2007), foi implementado um método de assimilação de dados no instante imediatamente anterior ao da previsão hidrológica, levando em consideração o erro observacional do modelo hidrológico. Esse método encontra-se descrito no seguinte Capítulo do presente documento.

4 MATERIAL E MÉTODOS

4.1 Área de estudo

A área de estudo desta pesquisa compreende a bacia incremental da Usina Hidrelétrica de Itaipu, localizada na bacia do rio Paraná e delimitada a montante pelas Usinas Hidrelétricas de Porto Primavera, sobre o rio Paraná, e de Rosana, sobre o rio Paranapanema (Figura 4.1).

Tal bacia possui uma área de aproximadamente 147.000 km², podendo ser dividida em seis grandes regiões: as cinco sub-bacias conformadas pelos principais afluentes da bacia incremental, que drenam ao rio Paraná (rios Ivinhema, Amambaí e Iguatemi, pela margem direita, e rios Ivaí e Piquiri, pela margem esquerda), cujas áreas até o posto fluviométrico correspondente encontram-se hachuradas; e uma bacia designada como “não-monitorada”, compreendida pela área não hachurada da Figura 4.1.

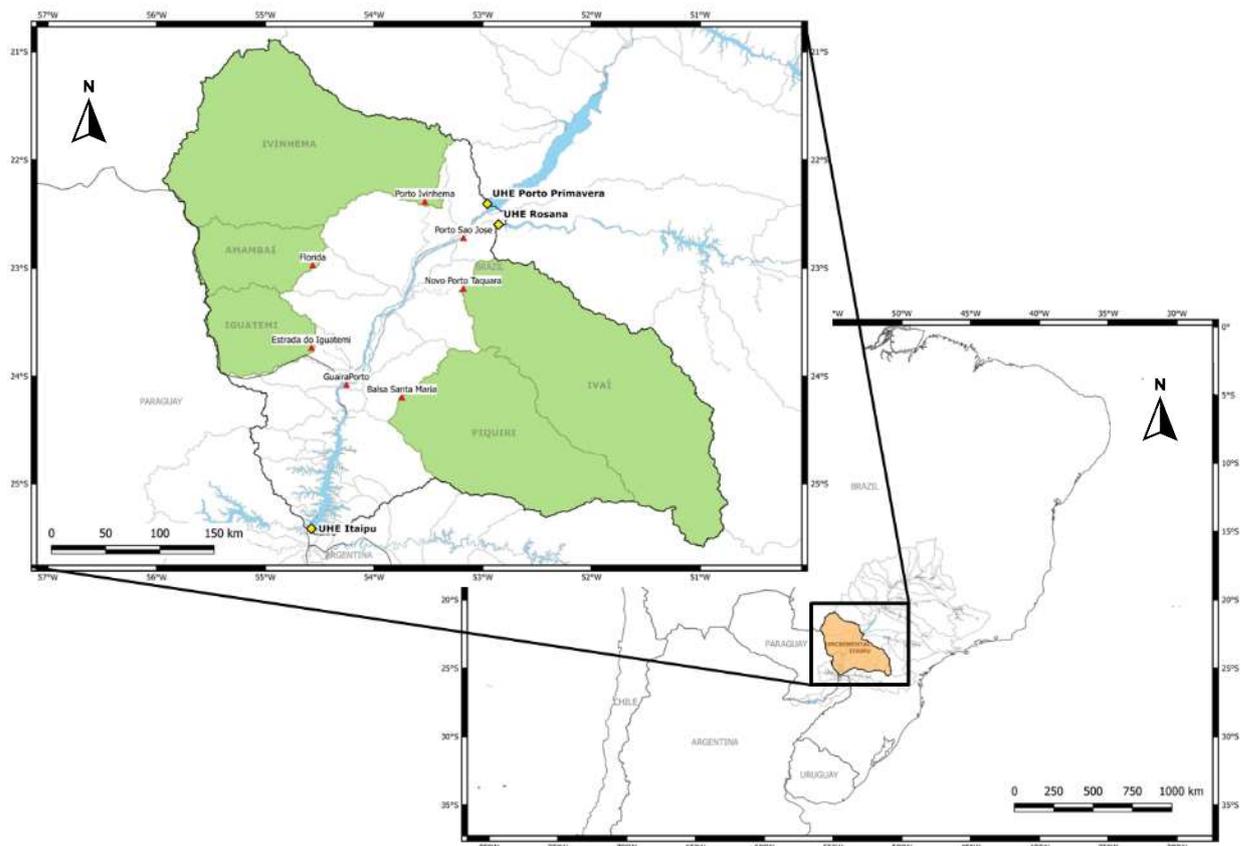
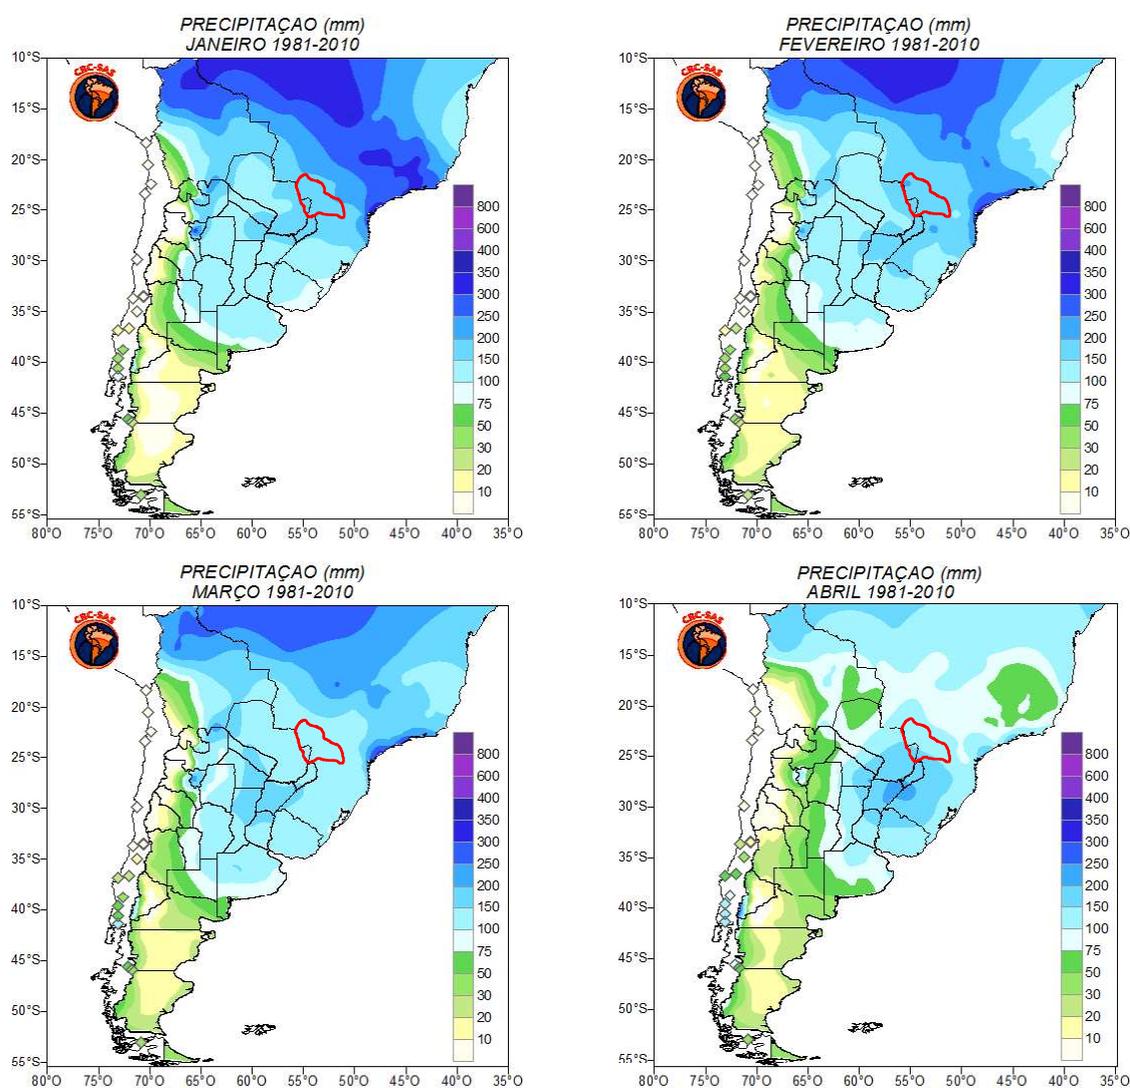
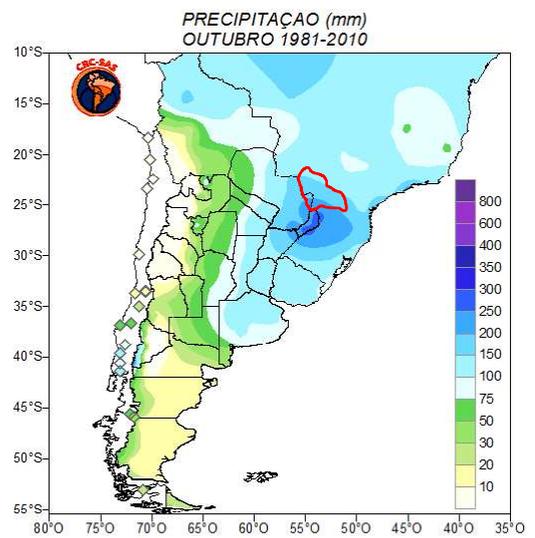
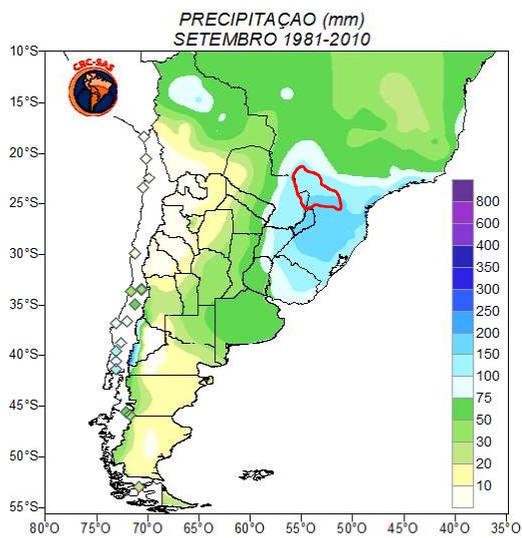
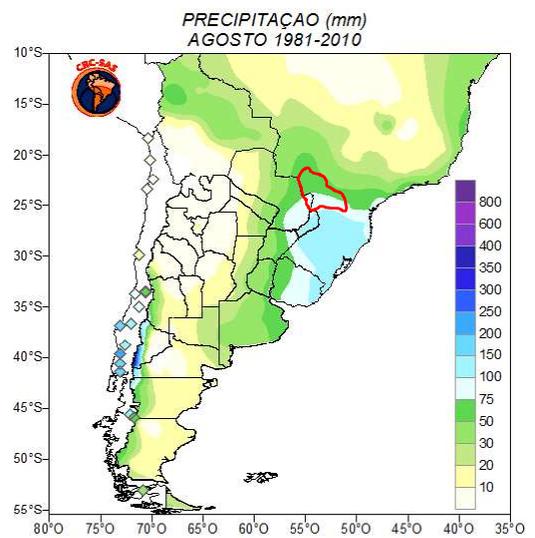
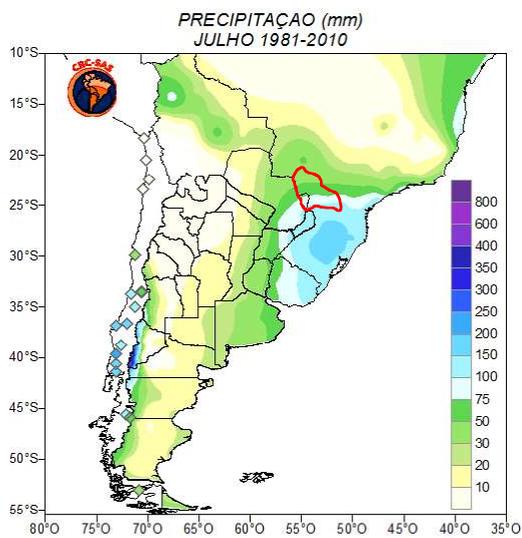
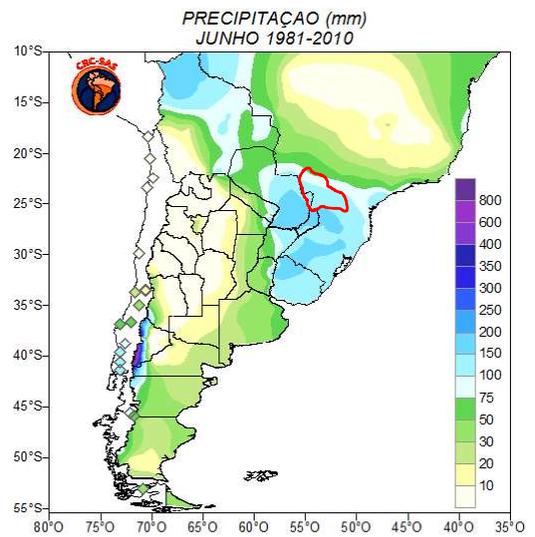
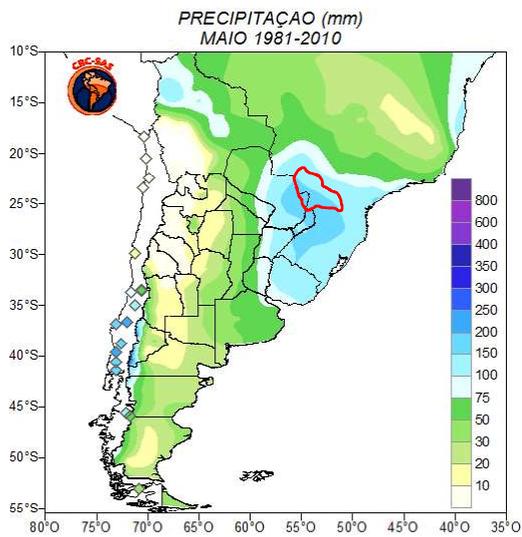


Figura 4.1 - Bacia incremental da UHE Itaipu, delimitada a montante pelas usinas de Porto Primavera e de Rosana.

Desse modo, a vazão afluente ao reservatório da UHE Itaipu pode ser dividida em duas grandes parcelas: (i) a vazão regularizada, proveniente das duas UHEs a montante, e que normalmente compreende a maior parte da vazão afluente à usina de Itaipu; e (ii) a vazão natural, aportada por sua bacia incremental, objeto de estudo deste trabalho.

As normais climatológicas (1981-2010) das precipitações médias mensais para a área de estudo encontram-se ilustradas na Figura 4.2. Observa-se que as precipitações são bem distribuídas ao longo de praticamente todo ano (médias de 100 a 200 mm médios mensais), com os menores volumes precipitados normalmente nos meses de junho a agosto (20 a 100 mm médios mensais). Desse modo, diferentemente de outras regiões do Brasil (e.g. região Sudeste), na região estudada a sazonalidade intra-anual das precipitações não é tão bem demarcada.





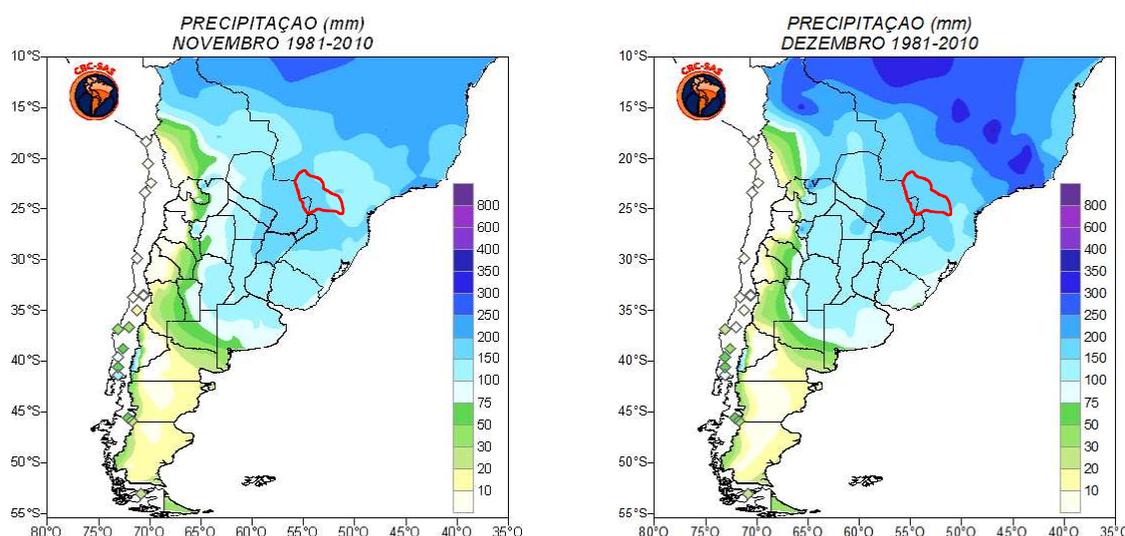


Figura 4.2 - Normais climatológicas das precipitação média mensais, com destaque para a bacia incremental de Itaipu (Fonte: CRC-SAS, 2021).

4.2 Dados hidrometeorológicos

A primeira etapa da pesquisa consistiu no levantamento e na caracterização das séries históricas de informações hidrometeorológicas de interesse para a área de estudo e necessárias à calibração do modelo SMAP mensal. Essas informações compreendem dados de precipitação, de vazão e de evapotranspiração potencial (ETP), com discretização mensal.

As séries de dados de precipitação e de vazão foram obtidos do próprio banco de dados hidrometeorológicos da ITAIPU Binacional, empresa operadora da Usina Hidrelétrica de Itaipu, e as séries de precipitação foram complementados com dados públicos disponibilizados no Portal HidroWeb, da Agência Nacional de Águas e Saneamento Básico (ANA, 2020).

Tais informações foram compiladas e consistidas para o período de janeiro/2004 a julho/2019, comum às seis sub-bacias. Esses dados, disponíveis em base temporal horária, foram transformados para a base mensal para sua utilização no modelo SMAP, a partir de macros elaboradas em linguagem VBA (*Visual Basic for Application*) incorporadas a planilhas Microsoft Excel®. Para a determinação da chuva média por sub-bacia, foi utilizada a média aritmética simples dos dados dos postos pluviométricos inseridos em sua respectiva área de drenagem.

Os postos pluviométricos (PLU) e fluviométricos (FLU) utilizados encontram-se resumidos na Tabela 4.1, e a sua disposição espacial pode ser visualizada na Figura 4.3.

Tabela 4.1 - Postos hidrometeorológicos utilizados na calibração do modelo SMAP.

Sub-bacia	Estação	Tipo	Fonte	Lat	Lon
Amambai	Flórida	PLU, FLU	BD Itaipu	-22,97°	-54,56°
Amambai	Bacajá	PLU	HidroWeb	-22,73°	-55,24°
Amambai	Amambaí	PLU	HidroWeb	-23,10°	-55,24°
Iguatemi	Estrada do Iguatemi	PLU, FLU	BD Itaipu	-23,73°	-54,58°
Iguatemi	Iguatemi	PLU	HidroWeb	-23,68°	-54,56°
Iguatemi	Tacuru	PLU	HidroWeb	-23,64°	-55,02°
Ivaí	Novo Porto Taquara	PLU, FLU	BD Itaipu	-23,19°	-53,18°
Ivaí	P. Paraíso do Norte	PLU	BD Itaipu	-23,32°	-52,67°
Ivaí	Paranavaí	PLU	BD Itaipu	-23,08°	-52,43°
Ivaí	Cianorte	PLU	BD Itaipu	-23,65°	-52,55°
Ivaí	Maringá	PLU	BD Itaipu	-23,45°	-51,99°
Ivaí	Campo Mourão	PLU	BD Itaipu	-24,05°	-52,37°
Ivaí	Barbosa Ferraz	PLU	BD Itaipu	-24,17°	-51,95°
Ivaí	Ubá Do Sul	PLU	BD Itaipu	-24,04°	-51,62°
Ivaí	Manuel Ribas	PLU	BD Itaipu	-24,51°	-51,66°
Ivaí	Cândido de Abreu	PLU	BD Itaipu	-24,63°	-51,24°
Ivaí	Tereza Cristina	PLU	BD Itaipu	-24,83°	-51,14°
Ivinhema	Porto Ivinhema	PLU, FLU	BD Itaipu	-22,38°	-53,53°
Ivinhema	Ivinhema	PLU	HidroWeb	-22,41°	-54,24°
Ivinhema	Glória de Dourados	PLU	HidroWeb	-22,30°	-53,83°
Ivinhema	Maracaju	PLU	HidroWeb	-21,62°	-55,14°
Ivinhema	Aroeira	PLU	HidroWeb	-21,65°	-54,43°
Piquiri	Balsa Santa Maria	PLU, FLU	BD Itaipu	-24,19°	-53,74°
Piquiri	Assis Chateaubriand	PLU	BD Itaipu	-24,39°	-53,54°
Piquiri	Novo Porto 2	PLU	BD Itaipu	-24,38°	-53,16°
Piquiri	Ubiratã	PLU	BD Itaipu	-24,55°	-52,99°
Piquiri	Balsa Do Cantú	PLU	BD Itaipu	-24,75°	-52,70°
Piquiri	Marquinho	PLU	BD Itaipu	-25,10°	-52,27°
Piquiri	Palmital	PLU	BD Itaipu	-24,88°	-52,22°

Sub-bacia	Estação	Tipo	Fonte	Lat	Lon
Piquiri	Santa Maria	PLU	BD Itaipu	-24,93°	-51,88°
Não-monitorada	Porto São José	PLU	BD Itaipu	-22,72°	-53,18°
Não-monitorada	Porto Caiuá	PLU	BD Itaipu	-23,45°	-54,19°
Não-monitorada	P. Salto del Guairá	PLU	BD Itaipu	-24,06°	-54,30°
Não-monitorada	Capitan Ortiz	PLU	BD Itaipu	-24,28°	-54,30°
Não-monitorada	Carapá	PLU	BD Itaipu	-24,31°	-54,45°
Não-monitorada	Limoy	PLU	BD Itaipu	-24,76°	-54,45°
Não-monitorada	S. Francisco Falso	PLU	BD Itaipu	-24,96°	-54,17°
Não-monitorada	Paulistânia	PLU	BD Itaipu	-25,51°	-54,60°
Não-monitorada	Santa Helena	PLU	BD Itaipu	-24,92°	-54,31°
Não-monitorada	Toledo	PLU	BD Itaipu	-24,78°	-53,72°
Não-monitorada	Cascavel	PLU	BD Itaipu	-24,88°	-53,55°
Não-monitorada	S. Miguel do Iguaçu	PLU	BD Itaipu	-25,35°	-54,25°
Não-monitorada	Foz do Iguaçu	PLU	BD Itaipu	-25,41°	-54,62°

PLU: estação pluviométrica; FLU: estação fluviométrica; BD Itaipu: Banco de Dados da ITAIPU Binacional.

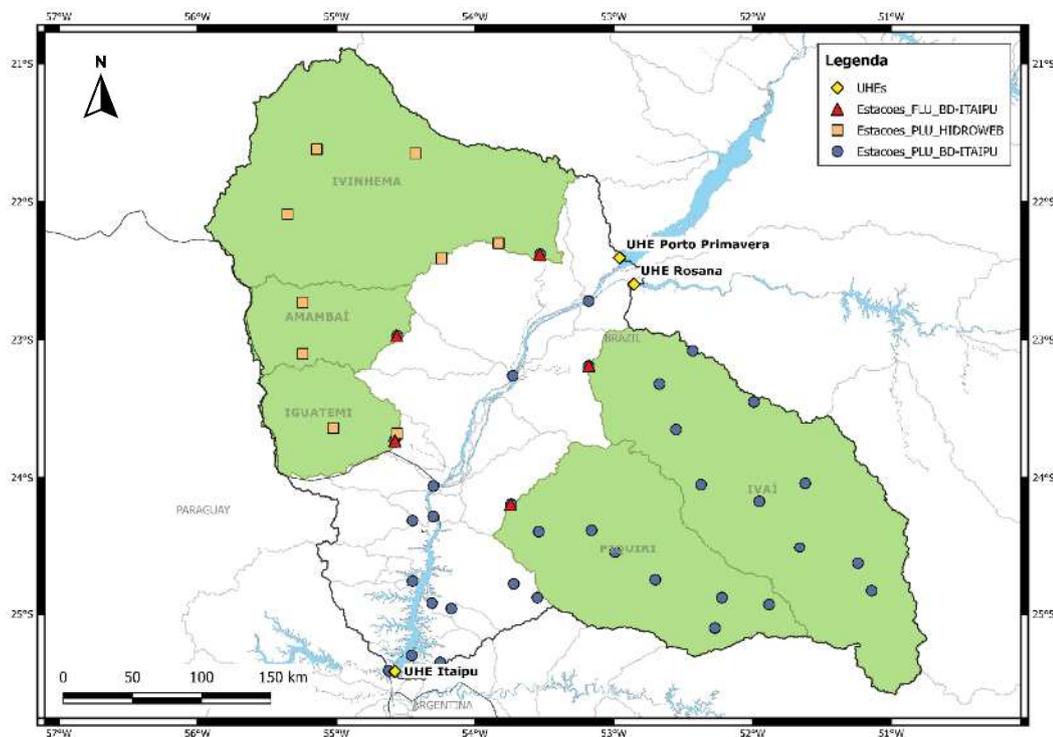


Figura 4.3 - Disposição espacial dos postos fluviométricos e pluviométricos utilizados para a calibração do SMAP.

Já as informações de ETP foram obtidas das normais climatológicas das estações meteorológicas do Sistema de Suporte à Decisão na Agropecuária (SISDAGRO), do Instituto Nacional de Meteorologia (INMET, 2020). Dessas estações foram obtidas as médias mensais de ETP para cada sub-bacia.

As estações utilizadas para a determinação da ETP média mensal encontram-se resumidas na Tabela 4.2, e a sua disposição espacial pode ser visualizada na Figura 4.4.

Tabela 4.2 - Postos hidrometeorológicos utilizados na calibração do modelo SMAP.

Sub-bacia	Estação	Tipo	Fonte	Lat	Lon
Amambaí	Juti	Meteorológica	INMET	-22,86°	-54,61°
Amambaí	Amambaí	Meteorológica	INMET	-23,00°	-55,33°
Iguatemi	Sete Quedas	Meteorológica	INMET	-23,97°	-55,02°
Ivaí	Cidade Gaúcha	Meteorológica	INMET	-23,36°	-52,93°
Ivaí	Ivaí	Meteorológica	INMET	-25,01°	-50,85°
Ivaí	Nova Tebas	Meteorológica	INMET	-24,44°	-51,96°
Ivinhema	Ivinhema	Meteorológica	INMET	-22,30°	-53,82°
Ivinhema	Dourados	Meteorológica	INMET	-22,19°	-54,91°
Piquiri	Goioerê	Meteorológica	INMET	-24,16°	-53,03°
Não-monitorada	Icaraíma	Meteorológica	INMET	-23,39°	-53,64°
Não-monitorada	Itaquirai	Meteorológica	INMET	-23,45°	-54,18°
Não-monitorada	Iguatemi	Meteorológica	INMET	-23,64°	-54,57°
Não-monitorada	Mal. C. Rondon	Meteorológica	INMET	-24,53°	-54,02°
Não-monitorada	Foz do Iguaçu	Meteorológica	INMET	-25,60°	-54,48°

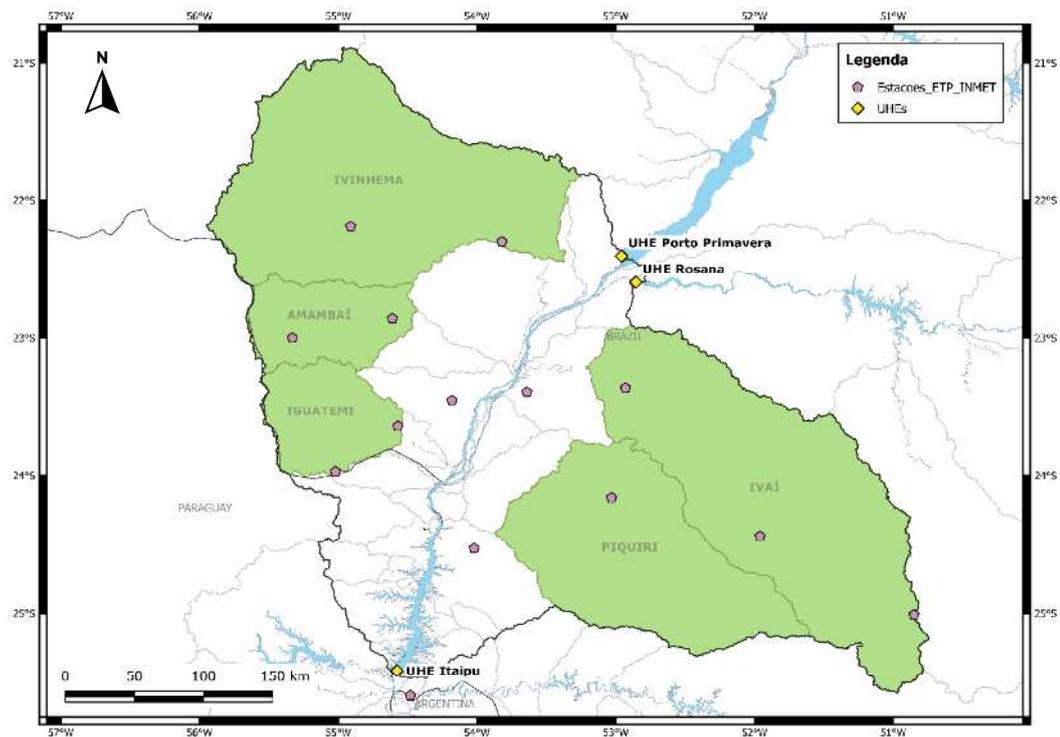


Figura 4.4 - Disposição espacial das estações meteorológicas do INMET, cujas normais climatológicas foram utilizadas no cálculo da ETP média de cada sub-bacia.

4.3 Calibração do modelo hidrológico

Após o levantamento dos dados hidrometeorológicos anteriormente descritos, definiu-se o *layout* de simulação da área de estudo, com a mesma discretização apresentada na Figura 4.1. Dessa forma, foram modeladas seis sub-bacias, com as seguintes áreas de drenagem (AD):

- Sub-bacia do rio Ivaí: $AD = 36.130 \text{ km}^2$ até a estação fluviométrica Novo Porto Taquara (NPT);
- Sub-bacia do rio Piquiri: $AD = 23.127 \text{ km}^2$ até a estação fluviométrica Balsa Santa Maria (BSM);
- Sub-bacia do rio Ivinhema: $AD = 34.681 \text{ km}^2$ até a estação fluviométrica Porto Ivinhema (IVI);
- Sub-bacia do rio Amambaí: $AD = 7.907 \text{ km}^2$ até a estação fluviométrica Flórida (FLO);
- Sub-bacia do rio Iguatemi: $AD = 7.866 \text{ km}^2$ até a estação fluviométrica Estrada do Iguatemi (IGT); e
- Sub-bacia “não-monitorada”: $AD = 37.289 \text{ km}^2$.

Para cada uma dessas seis sub-bacias, realizou-se a calibração do modelo hidrológico SMAP, em sua versão mensal, para o período de janeiro/2004 a julho/2019. Para tanto, foram utilizadas as séries de vazão das estações fluviométricas sobre a foz de cada um de seus respectivos rios e a precipitação e ETP médias mensais de cada sub-bacia. No caso da bacia “não-monitorada” (BNM), a vazão foi estimada a partir da diferença entre a vazão afluente ao reservatório de Itaipu, a vazão regularizada pelas usinas a montante e a soma das vazões dos cinco afluentes, medidas em seus respectivos postos fluviométricos (Equação (4.1)).

$$Q_{BNM} = Q_{afIIPU} - (Q_{defPRI} + Q_{defROS}) - (Q_{BSM} + Q_{NPT} + Q_{IVI} + Q_{FLO} + Q_{IGT}) \quad (4.1)$$

4.3.1 Calibração convencional

Em uma etapa prévia à calibração pelo método GLUE, foi realizada a calibração convencional do modelo SMAP para cada uma das seis sub-bacias modeladas, como forma de análise de sensibilidade da resposta do modelo às variações em cada um de seus parâmetros.

Para a determinação a priori dos parâmetros do modelo, utilizou-se o *software* SH30, disponibilizado gratuitamente pelo Departamento de Engenharia Hidráulica e Recursos Hídricos (EHR, 2020) da Universidade Federal de Minas Gerais (UFMG). O SH30 realiza a calibração de parâmetros e a simulação chuva-vazão, em intervalo mensal, dos modelos SMAP e RIO GRANDE, sendo a calibração processada em modo automático por meio do DDS (*Dynamically Dimensioned Search*), um algoritmo de busca desenvolvido por Tolson (2005) e introduzido para a calibração de modelos hidrológicos por Tolson e Shoemaker (2007). O DDS possui a finalidade de encontrar soluções satisfatórias ou otimizadas, diferentemente das soluções que buscam um ótimo global, a partir de um limite máximo de avaliações da função-objetivo, a qual é especificada pelo próprio usuário. Maiores detalhes sobre o algoritmo DDS podem ser encontrados nos trabalhos de Tolson (2005) e Tolson e Shoemaker (2007).

Assim, os valores obtidos a partir dessa calibração automática foram utilizados como uma primeira estimativa dos parâmetros do modelo SMAP, para cada sub-bacia modelada no presente trabalho.

Em seguida, por tentativa e erro, fez-se a modificação manual de cada um dos parâmetros das sub-bacias modeladas, mantendo-se os demais constantes. A cada modificação, foi feita uma avaliação multicritério quanto à resposta do modelo, utilizando para tanto as seguintes métricas:

Erro médio absoluto, ou MAE (*Mean Absolute Error*):

$$MAE = \frac{1}{T} \sum_{t=1}^T |QS_t - QO_t| \quad (4.2)$$

Erro médio relativo, ou MRE (*Mean Relative Error*):

$$MRE = \frac{1}{T} \sum_{t=1}^T \frac{|QS_t - QO_t|}{|QO_t|} \quad (4.3)$$

Raiz do erro médio quadrático, ou RMSE (*Root Mean Square Error*):

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (QS_t - QO_t)^2}{T}} \quad (4.4)$$

Coefficiente de eficiência de Nash-Sutcliffe (NSE):

$$NSE = 1 - \frac{\sum_{t=1}^T (QS_t - QO_t)^2}{\sum_{t=1}^T (QO_t - \overline{QO})^2} \quad (4.5)$$

sendo QS_t e QO_t a vazão simulada e a vazão observada no instante t , respectivamente; \overline{QO} a vazão média observada ao longo do período; e T o período total de calibração.

As métricas MAE e RMSE fornecem a média da magnitude dos erros sem indicar o sinal do desvio, e podem variar de 0 a ∞ , sendo 0 o ajuste perfeito. Comparado ao MAE, o RMSE dá maior peso a maiores desvios sendo, portanto, uma métrica mais apropriada quando se deseja penalizar grandes erros e promover previsões mais conservadoras; no entanto, dada sua maior sensibilidade a grandes erros, pode não fornecer estimativas estáveis de erro se pequenas amostras forem utilizadas (STANSKI et al., 1989). O MRE, por sua vez, é o erro médio absoluto (MAE) dividido pelo valor exato da grandeza, sendo, portanto, adimensional e podendo variar entre 0 e 1, sendo 0 o ajuste perfeito.

Já o NSE mede o quanto os resultados do modelo são melhores do que a média de longo período dos dados observados. Seu valor é adimensional e pode variar entre $-\infty$ a 1, sendo que valores acima de 0 indicam que o desempenho do modelo é superior à média de longo termo; valores próximos de 0 indicam que o modelo tem o mesmo desempenho da média; e valores negativos indicam que o modelo tem desempenho pior do que se utilizar a média dos dados observados. O NSE tende a penalizar erros nos maiores valores de vazão (e.g. picos), de forma que a calibração do modelo apenas com o objetivo de maximizar o NSE pode resultar em um mau ajuste nos períodos de baixas vazões (recessões) (FAN, 2015).

Para a avaliação do ajuste do modelo, considerou-se um período de aquecimento do modelo de 10 meses, os quais não foram computados nos cálculos das métricas supracitadas. Esse período foi identificado como o tempo necessário para reduzir a interferência da inicialização dos estados do modelo nas simulações, conforme também observado por Saraiva (2010).

A partir desse exercício, foi possível desenvolver uma sensibilidade acerca da resposta do modelo diante da variação de cada um dos parâmetros. Além disso, identificou-se que as faixas de valores obtidos da literatura (LOPES, 1999) para os parâmetros calibráveis do SMAP não eram suficientes para a representação das bacias modeladas, de forma que tais limites foram estendidos aos valores indicados na Tabela 4.3.

Tabela 4.3 - Limites estendidos dos parâmetros calibráveis do SMAP.

Parâmetro	Limite Inferior	Limite Superior
SAT (mm)	0	5.000
CREC (ad.)	0	0,9
K (mês ⁻¹)	0,1	0,9
E2 (ad.)	0,1	20

4.3.2 Calibração pelo método GLUE

Tendo-se em vista o conceito de equifinalidade, o método GLUE foi utilizado para avaliar os demais conjuntos de parâmetros igualmente hábeis em reproduzir o comportamento das séries de vazões observadas em cada sub-bacia modelada. Para viabilizar a aplicação do GLUE, foram

elaborados *scripts* em linguagem R, devido ao caráter estocástico do método. A metodologia aqui descrita foi aplicada para cada uma das seis sub-bacias modeladas.

Primeiramente, foram realizadas 100.000 simulações estocásticas de Monte Carlo para amostragem dos conjuntos de parâmetros do SMAP a partir de suas distribuições definidas a priori, no intento de se percorrer todo o espaço paramétrico. Dado o pouco conhecimento prévio sobre esses parâmetros, definiu-se uma distribuição uniforme para cada um deles, cujos limites foram os mesmos utilizados na calibração convencional (Tabela 4.3).

Cada um dos conjuntos de parâmetros amostrados foi utilizado para a simulação do modelo SMAP mensal, e as séries simuladas foram então comparadas com a série de vazões observadas. Como medida de verossimilhança foi definido o coeficiente de eficiência Nash-Sutcliffe, determinando-se, a priori, o valor de corte de 0,60 para separar os conjuntos de parâmetros comportamentais dos não-comportamentais.

Para os conjuntos comportamentais, os valores de verossimilhança foram normalizados de forma a se obterem os pesos associadas a cada um desses conjuntos, utilizando para tanto a Equação (4.6):

$$w_p^{\theta_i} = \frac{L(\theta_i)}{\sum_{k=1}^N L(\theta_k)} \quad (4.6)$$

sendo $w_p^{\theta_i}$ o peso associado ao conjunto de parâmetros θ_i ; $L(\theta_i)$ a medida de verossimilhança desse mesmo conjunto; N o número de conjuntos de parâmetros comportamentais obtidos pela metodologia; e $L(\theta_k)$ a verossimilhança de cada um destes conjuntos.

Desse modo, àqueles conjuntos de parâmetros comportamentais que apresentaram maiores valores da medida de verossimilhança foram atribuídos maiores pesos, indicando um melhor desempenho, e vice-versa.

A partir das N séries de vazões simuladas por meio dos conjuntos de parâmetros comportamentais, foram gerados os limites de incerteza de 95%, aqui denominados *UL95*, e foi avaliado o percentual das séries observadas (medições) inseridas nesses limites.

4.4 Atualização das variáveis de estado

A atualização das variáveis de estado do modelo hidrológico foi a técnica de assimilação de dados utilizada no presente trabalho, buscando-se reduzir o erro da simulação no instante imediatamente anterior ao da previsão. Assim, com base no desempenho da simulação no mês anterior ao do início da previsão (m_{f-1}), foi calculada a verossimilhança do conjunto de variáveis de estado que a gerou (ou seja, as variáveis de estado do instante m_{f-2}), determinada pela Equação (4.7):

$$L(\theta_e)^{j, m_{f-2}, \theta_i} = \frac{1}{\varepsilon^{j, m_{f-1}, \theta_i}}, \quad j = 1, \dots, n; m = jan, \dots, dez \quad (4.7)$$

sendo θ_e o conjunto das variáveis de estado R_{solo} e R_{sub} do instante m_{f-2} ; $\varepsilon^{j, m_{f-1}, \theta_i} = |QS^{j, m_{f-1}, \theta_i} - QO^{j, m_{f-1}}|$ o erro absoluto da simulação no mês m do ano j do instante m_{f-1} , gerada pelo conjunto de parâmetros θ_i ; e n o número de anos do período simulado.

Semelhantemente, foram calculadas as verossimilhanças de todas as variáveis de estado dos instantes imediatamente anteriores ao mesmo mês m analisado, ou seja, do mês $(m - 1)$ (por exemplo, supondo a previsão começando em janeiro, foram avaliados os erros da simulação de todos os meses de dezembro contidos nos n anos da calibração, e a partir destes foram calculadas as verossimilhanças das variáveis de estado que as geraram, ou seja, as de todos os meses de novembro). Desse modo, generalizando-se a Equação (4.7), tem-se que:

$$L(\theta_e)^{j, (m-1), \theta_i} = \frac{1}{\varepsilon^{j, m, \theta_i}}, \quad j = 1, \dots, n; m = jan, \dots, dez \quad (4.8)$$

A partir dessas verossimilhanças, foram inferidos os pesos $w(\theta_e)^{j, (m-1), \theta_i}$ para cada mês $(m - 1)$ do período de calibração, normalizados pelo somatório das verossimilhanças de todos os meses $(m - 1)$ contidos nos n anos calibrados, conforme a Equação (4.9):

$$w(\theta_e)^{j, (m-1), \theta_i} = \frac{L(\theta_e)^{j, (m-1), \theta_i}}{\sum_{j=1}^n L(\theta_e)^{j, (m-1), \theta_i}} \quad (4.9)$$

Desse modo, as variáveis de estado que geraram a vazão simulada no mês m_{f-1} anterior ao início da previsão, ou seja, as variáveis de estado do mês m_{f-2} , foram atualizadas a partir da média ponderada de todas as variáveis daquele mesmo mês e seus respectivos pesos, conforme indicado pela Equação (4.10):

$$\hat{\theta}_e^{m_{f-2}, \theta_i} = \sum_{j=1}^n \theta_e^{j, (m-1), \theta_i} \times w(\theta_e)^{j, (m-1), \theta_i} \quad (4.10)$$

4.5 Previsão de vazões e incorporação de incertezas

4.5.1 Previsão de precipitação

Para a obtenção de previsões hidrológicas de longo prazo, foram utilizadas as previsões climáticas sazonais por *ensemble* elaboradas pelo C3S (*Copernicus Climate Change Service*), o programa de monitoramento climático da Terra operado pelo ECMWF. O C3S é um dos seis serviços de informação temática do Programa *Copernicus*, o Programa de Observação da Terra da União Europeia (Figura 4.5).



Figura 4.5 - Serviços de informação temática do Programa Copernicus (Fonte: COPERNICUS, 2021).

Os produtos de previsão sazonal C3S são baseados em dados de vários sistemas de previsão sazonal de última geração. Os centros que atualmente fornecem previsões para o C3S são o

ECMWF, *The Met Office*, o *Météo-France*, o *Deutscher Wetterdienst* (DWD), o *Centro Euro-Mediterraneo sui Cambiamenti Climatici* (CMCC), o NCEP do Serviço Nacional de Meteorologia dos EUA e Agência Meteorológica do Japão (*Japan Meteorological Agency*, JMA) (C3S, 2021).

As previsões sazonais do C3S possuem horizonte de seis meses de previsão e são geradas operacionalmente todos os meses, no 13º dia de cada mês, às 12 UTC. O histórico dessas previsões é disponibilizado publicamente na base de dados do C3S, a *Climate Data Store* (CDS, 2020), podendo ser obtidas as combinações das previsões climáticas dos sistemas de previsão supracitados (previsões multissistema), ou as previsões individuais de cada um deles.

No presente trabalho, das previsões climáticas de precipitação do C3S, foram utilizadas apenas as provenientes do atual sistema de previsão sazonal do ECMWF, o SEAS5, que se encontra em operação desde novembro de 2017 (ECMWF, 2017; JOHNSON et al., 2019). Tais previsões possuem formato matricial GRIB (*General Regularly-distributed Information in Binary form*), resolução espacial horizontal de 1º x 1º (aproximadamente 100 x 100 km) e horizonte de até seis meses de previsão, com discretização mensal. O *ensemble* é composto por 51 membros, sendo um de controle e os outros 50 com as condições iniciais perturbadas.

A escolha das previsões provenientes do ECMWF foi feita com base no bom desempenho que elas têm demonstrado na estimação de precipitações futuras em estudos recentes (BUIZZA et al., 2005; FAN, 2015; WANG et al., 2019). Com a finalidade de se avaliar a variabilidade intra-anual do desempenho dessas previsões, foram obtidas doze séries de previsões climáticas de precipitação, com início em cada um dos doze meses do ano e horizontes de seis meses de previsão. Assim, foram descarregadas as previsões com início desde agosto/2018 até julho/2019, mês este correspondente ao final do período de calibração. Conforme destacado na Figura 4.6, o período analisado compreende a presença do fenômeno climático El Niño, ou seja, a fase positiva (quente) do indicador ENSO.

Uma vez descarregadas, tais previsões foram interpretadas e organizadas por meio de *script* elaborado em linguagem R. Em seguida, foram extraídas as informações dos pontos de grade do arquivo GRIB inseridos na área de estudo (Figura 4.7), e a partir destas foram calculadas as precipitações médias para cada uma das seis sub-bacias modeladas no SMAP, para cada mês do horizonte de previsão.

Assim, para cada uma das seis sub-bacia, foram obtidas 51 séries de precipitação prevista, de horizontes de 6 meses, cujas incertezas estavam representadas pelo espalhamento desse *ensemble*. É importante destacar que os dados dessas previsões foram utilizados de forma bruta, não sendo realizado nenhum tipo de pré-processamento para remoção de possíveis vieses.

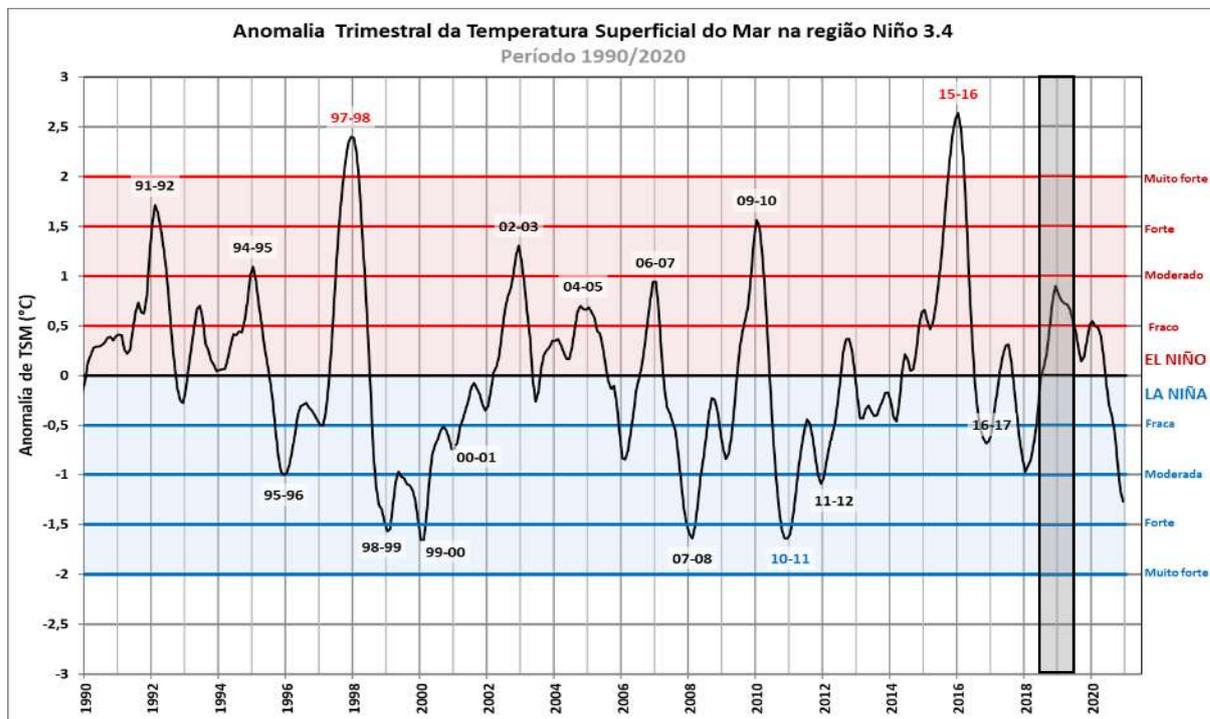


Figura 4.6 - Anomalia de Temperatura da Superfície do Mar na região Niño 3.4 do Oceano Pacífico Central e destaque para o período analisado (Fonte dos dados: CPC/NOAA, 2021).

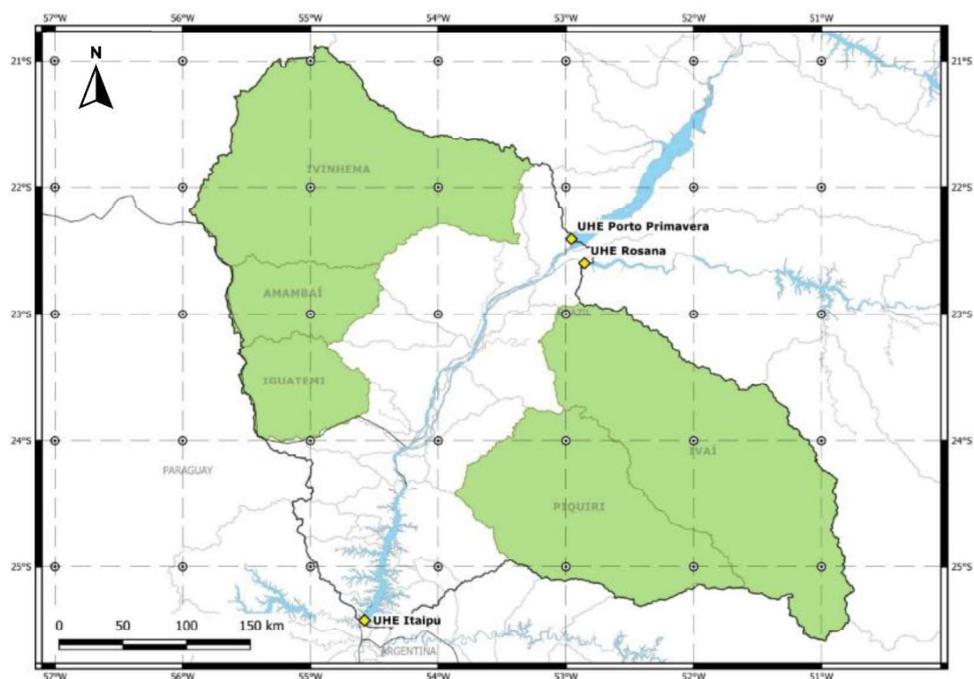


Figura 4.7 - Pontes de grade inseridos na área de estudo.

4.5.2 Previsão hidrológica

4.5.2.1 Previsão para as sub-bacias

De forma a se incorporarem tanto as incertezas acerca das previsões climáticas, representadas pelo espalhamento do *ensemble*, quanto a incerteza paramétrica do modelo hidrológico, representada pelos pesos $w_p^{\theta_i}$ dos conjuntos de parâmetros comportamentais resultantes da calibração pelo GLUE, foi elaborado em linguagem R o seguinte pseudo-algoritmo, aplicado para cada uma das seis sub-bacias modeladas:

Faça:

para cada previsão climática de horizonte $f = 1, \dots, 6$

para cada membro k da previsão climática ($k = 1, \dots, 51$)

para cada conjunto de parâmetros θ_i

calcular a série de vazões previstas q_f^{k, θ_i} ($f = 1, \dots, 6$),

impondo os estados $\hat{\theta}_e^{m_{f-2}, \theta_i}$ no instante $f - 2$

estimar a vazão média ponderada pelos pesos $w_p^{\theta_i}$ para o membro k , para cada mês previsto f

$$\bar{Q}_f^k = \sum_i w_p^{\theta_i} \times q_f^{k, \theta_i} \quad (4.11)$$

calcular o erro da previsão para cada mês previsto f

$$\varepsilon_f = |QO_f - QP_f|, \text{ onde}$$

$$QP_f = \text{Med}(\bar{Q}_f^k)$$

calcular o desempenho global da previsão

Assim, para cada série de previsão climática, obteve-se um *ensemble* de previsões hidrológicas (ESP) composto por 51 trajetórias \bar{Q}_f^k , cada qual com seis meses de horizonte previsto. Desse ESP, foram determinados a mediana e o limites de incerteza de 90% (UL90) para cada mês de previsão. A partir dos valores da mediana, foram calculados os erros de cada mês previsto, e foi avaliado o desempenho global da previsão, por meio das métricas indicadas pelas Equações (4.2) a (4.5).

4.5.2.2 Afluência à Itaipu

Para se obter a estimativa real da vazão afluente ao reservatório de Itaipu, seria necessária a avaliação de todas as possíveis combinações das séries \bar{Q}_f^k , ou seja, das 51 trajetórias de vazão entre as seis sub-bacias modeladas, o que resultaria em $51^6 = 17.596.287.801$ combinações. Devido à limitação computacional existente, o espaço amostral dessas possíveis combinações foi estimado de forma aproximada por meio de simulações estocásticas de Monte Carlo.

Desse modo, foram realizadas 10^6 simulações MC amostrando-se, de forma aleatória e com reposição, uma dentre as 51 séries de vazão prevista para cada sub-bacia. Para cada simulação, fez-se o somatório das seis séries amostradas e de uma série de seis valores constantes, um para cada mês do horizonte previsto. Esta última representa a série da vazão regularizada pelas usinas a montante, prevista para cada mês do horizonte e supostamente conhecida, a priori. O resultado desse somatório corresponde, portanto, à estimativa de uma das possíveis séries futuras de vazões afluentes ao reservatório de Itaipu.

Assim, obteve-se o ESP composto por 10^6 possíveis trajetórias. Desse *ensemble* pôde-se inferir a previsão probabilística das vazões afluentes ao reservatório de Itaipu, na qual estão refletidas as incertezas acerca da previsão de precipitação e aquelas associadas ao modelo hidrológico.

Por fim, foi avaliado o desempenho dessa previsão. Essa avaliação se deu primeiramente em termos determinísticos, utilizando como referência a mediana do *ensemble* e calculando-se as mesmas métricas utilizadas na avaliação do desempenho das previsões hidrológicas das sub-bacias modeladas (Equações (4.2) a (4.5)). Em seguida, foi feita a avaliação do conjunto de previsões como um todo, de modo a se avaliarem o erro, a destreza e a confiabilidade destas, a partir das métricas *Brier Score*, *Brier Skill Score* e *Reliability Diagram*.

Devido ao pequeno número de amostras avaliadas, de apenas doze séries de previsão, não foi possível gerar satisfatoriamente os *Reliability Diagram*, da maneira como descreve a literatura técnica (BRÖCKER e SMITH, 2007; WILKS, 2006). Desse modo, a avaliação da confiabilidade das previsões probabilísticas foi realizada de uma forma mais simplificada, avaliando-se a correspondência do percentual das observações inseridas nos intervalos de incerteza calculados a partir do *ensemble* de previsões, tal como aplicado nos trabalhos de Smith et al., 2010, Yadav et al., 2007 e Maldonado et al., 2018.

5 RESULTADOS E DISCUSSÃO

5.1 Calibração do modelo hidrológico

5.1.1 Calibração convencional

De uma maneira geral, os resultados da calibração convencional das sub-bacias modeladas foram considerados satisfatórios, indicando que, mesmo se tratando de um modelo simplificado, o SMAP foi capaz de reproduzir as vazões observadas dessas bacias, cujas áreas de drenagem apresentam entre 7.000 km² e 40.000 km².

As métricas avaliadas nessa calibração encontram-se resumidas na Tabela 5.1. Conforme mencionado no Capítulo anterior, no cômputo dessas métricas foram desconsiderados os primeiros 10 meses de simulação, correspondentes ao período de aquecimento do modelo.

Tabela 5.1 - Resultados da calibração convencional de cada uma das seis sub-bacias modeladas no SMAP (período de janeiro/2004 a julho/2019).

Sub-bacia	Área de drenagem (km ²)	QO _{méd} (m ³ /s)	QS _{méd} (m ³ /s)	MAE (m ³ /s)	MRE	RMSE (m ³ /s)	NSE
Rio Piquiri	23.127	547,3	547,0	131,4	0,2367	189,6	0,72
Rio Ivaí	36.130	795,9	795,8	202,8	0,2768	294,4	0,70
Rio Ivinhema	34.681	445,7	384,3	105,4	0,2187	152,9	0,46
Rio Amambaí	7.907	165,8	166,2	17,3	0,1032	25,4	0,87
Rio Iguatemi	7.866	160,7	159,3	26,2	0,1707	34,1	0,62
Não-monitorada	37.289	740,9	740,7	206,4	0,3671	268	0,52

Desses resultados observa-se que, à exceção da sub-bacia do rio Ivinhema, foi satisfatório o desempenho do modelo na representação das vazões médias observadas (QO_{méd}) das bacias modeladas. Além disso, percebe-se que, dos resultados de coeficientes de Nash-Sutcliffe (NSE), os menores valores obtidos foram para as bacias do rio Ivinhema e a “não-monitorada”, o que pode ser um indício de limitação estrutural do modelo hidrológico em representá-las e de possíveis incertezas quanto à própria vazão observada, principalmente no caso da bacia não-monitorada, em que essa vazão foi obtida de maneira indireta a partir da Equação (4.1).

Além disso, à exceção da bacia “não-monitorada”, foram verificados erros relativos médios relativamente baixos em todas as sub-bacias, inferiores a 30% (absolutos), e observou-se uma relação proporcional destes à área e à vazão média das sub-bacias, o que indica uma maior dificuldade do modelo em representar bacias de áreas de drenagem maiores.

Além das métricas, a comparação gráfica entre as séries observadas e simuladas também foi utilizada para a verificação da calibração convencional dos parâmetros do modelo. Os gráficos obtidos encontram-se ilustrados da Figura 5.1 até a Figura 5.6.

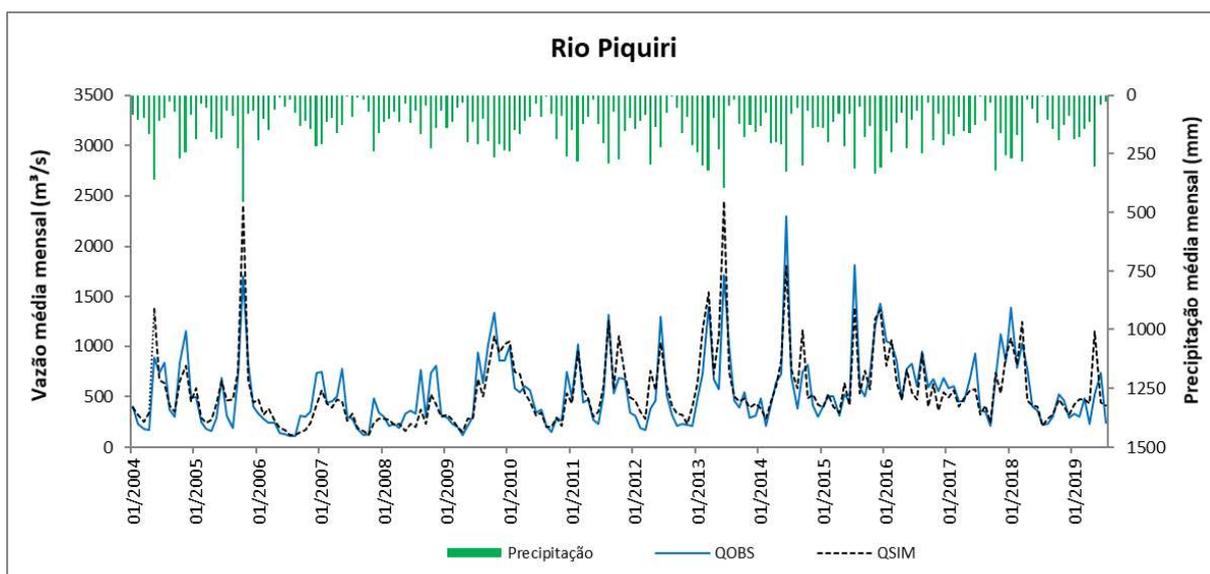


Figura 5.1 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Piquiri.

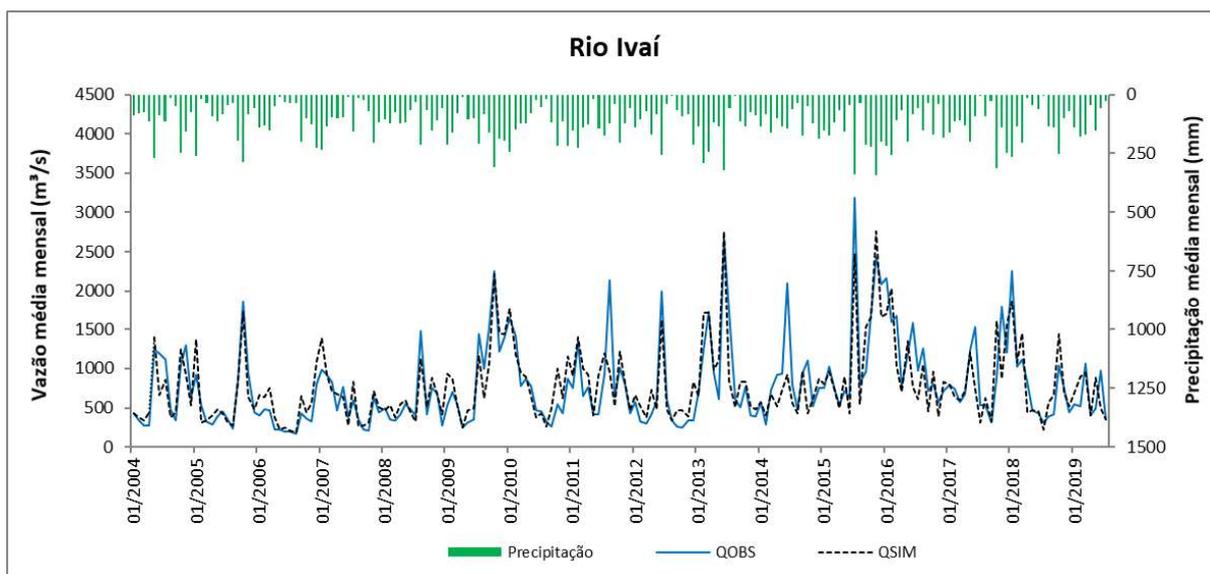


Figura 5.2 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Ivaí.

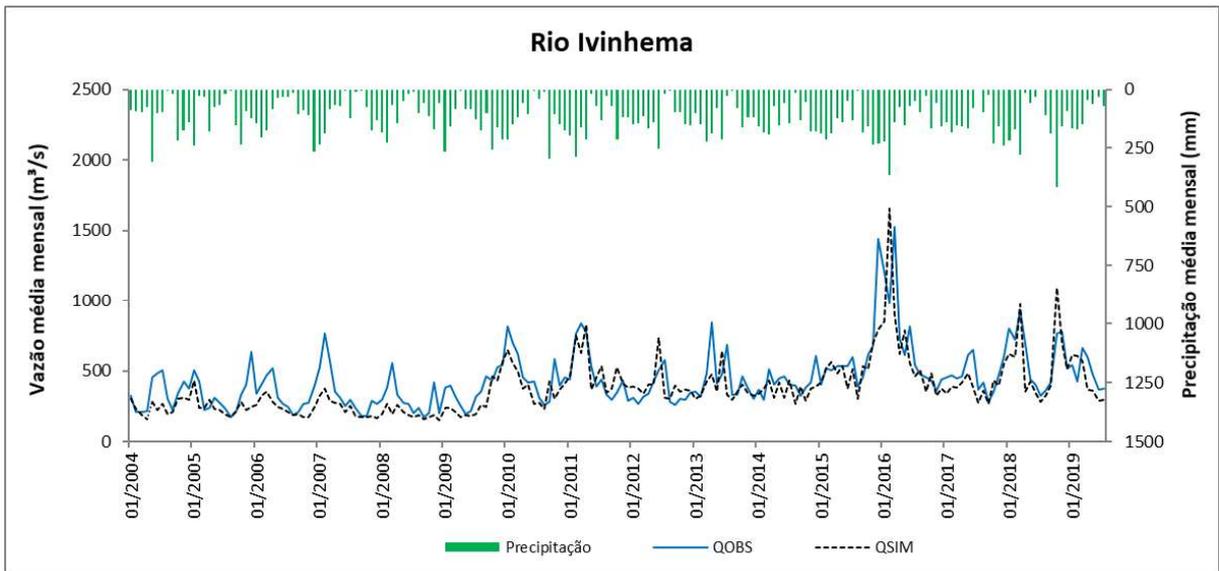


Figura 5.3 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Ivinhema.

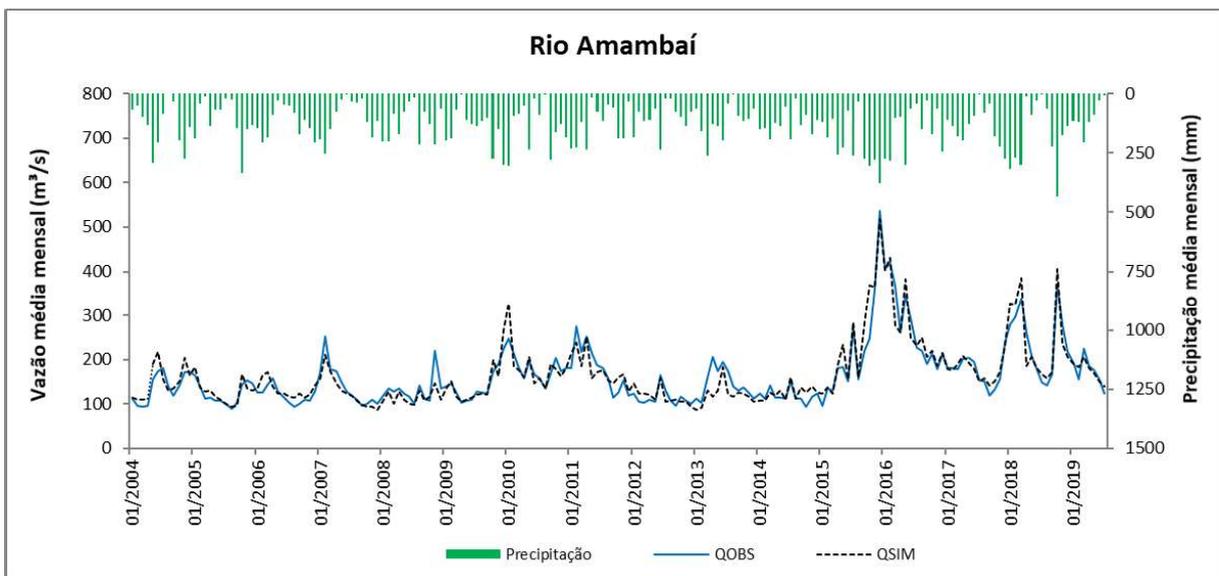


Figura 5.4 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Amambaí.

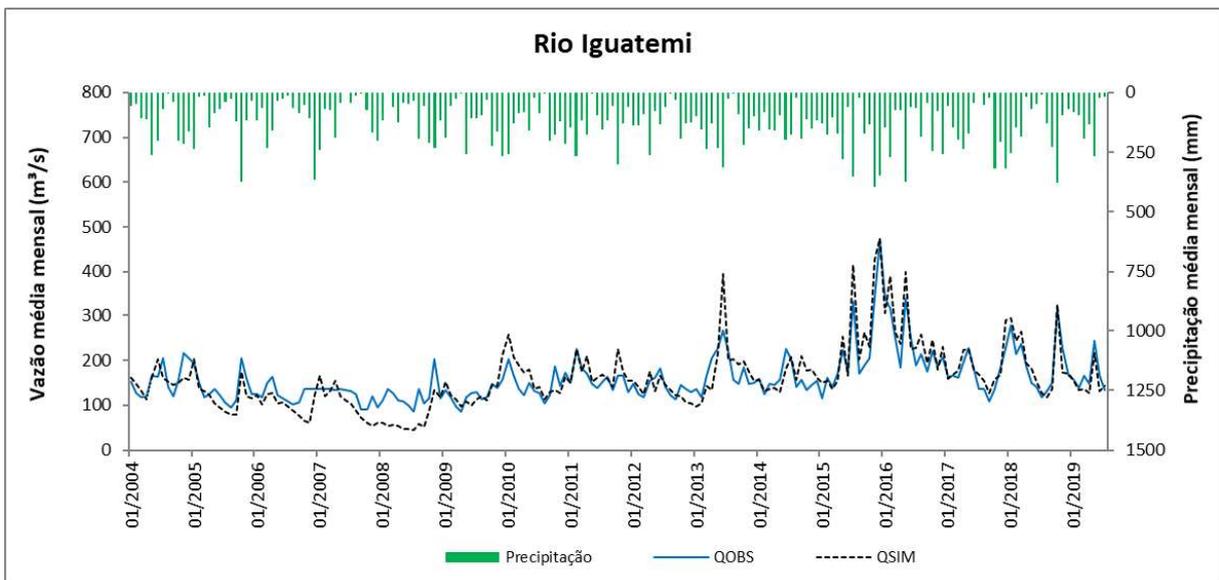


Figura 5.5 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia do rio Iguatemi.

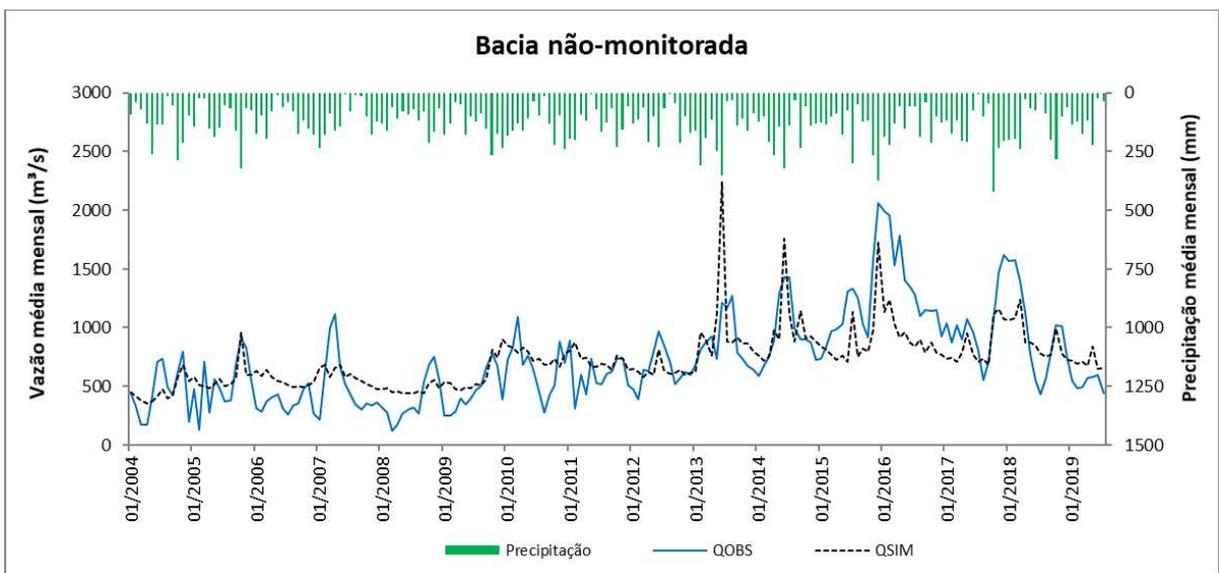


Figura 5.6 - Série de precipitação média e de vazões mensais observada e simulada pelo SMAP, para a sub-bacia “não-monitorada”.

A partir da avaliação qualitativa desses gráficos, percebe-se, de forma geral, um bom ajuste do modelo às sub-bacias modeladas, à exceção da bacia “não-monitorada”, para a qual os valores observados foram estimados. Também é possível observar, especialmente para as sub-bacias dos rios Ivinhema (Figura 5.3) e Iguatemi (Figura 5.5), que há uma maior aderência das simulações a partir do ano de 2011, o que pode ser um indicio de maiores incertezas acerca dos dados observacionais nos anos anteriores a este.

Para uma análise mais detalhada do ajuste do modelo, avaliou-se a correlação linear entre as vazões médias mensais observadas e as simuladas para cada sub-bacia, conforme indicado nos gráficos da Figura 5.7 até a Figura 5.12.

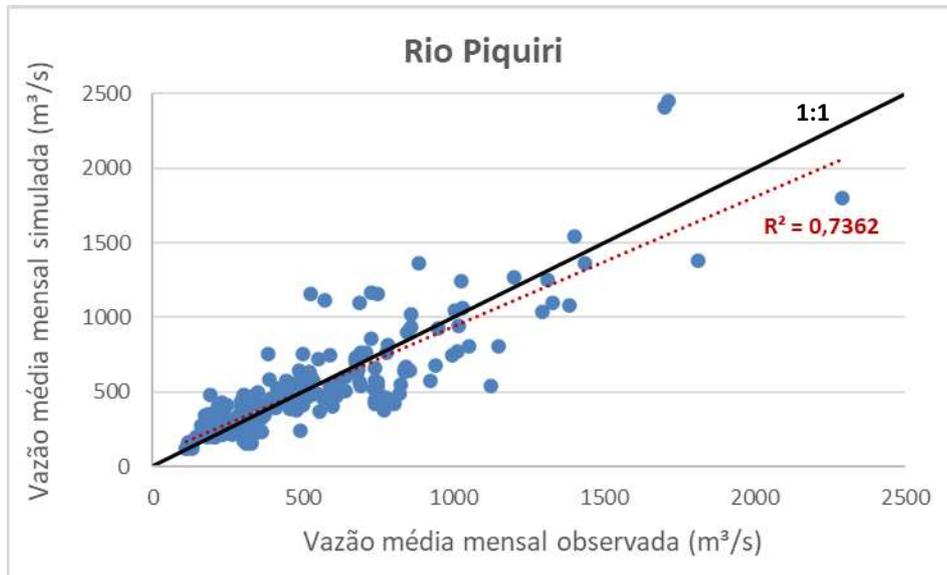


Figura 5.7 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Piquiri.

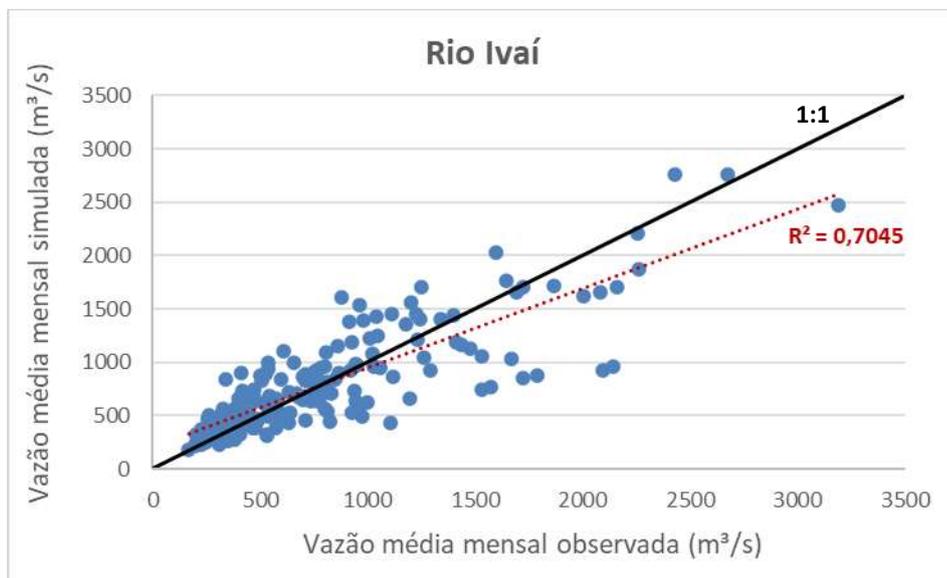


Figura 5.8 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Ivaí.

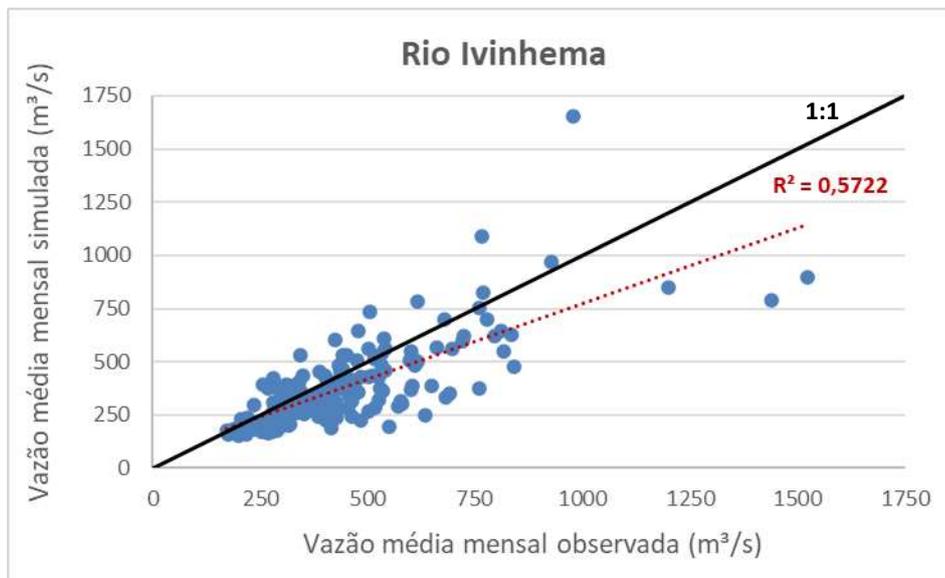


Figura 5.9 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Ivinhema.

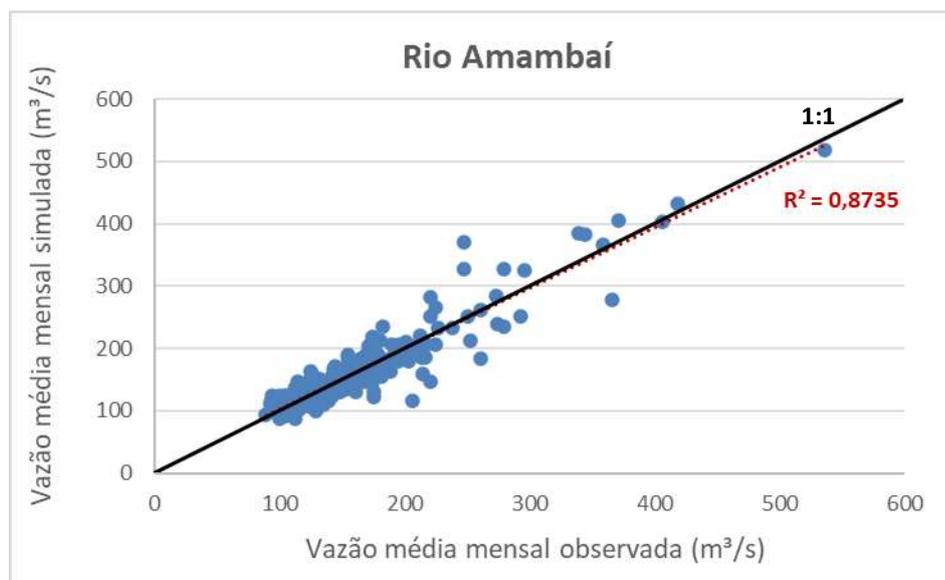


Figura 5.10 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Amambaí.

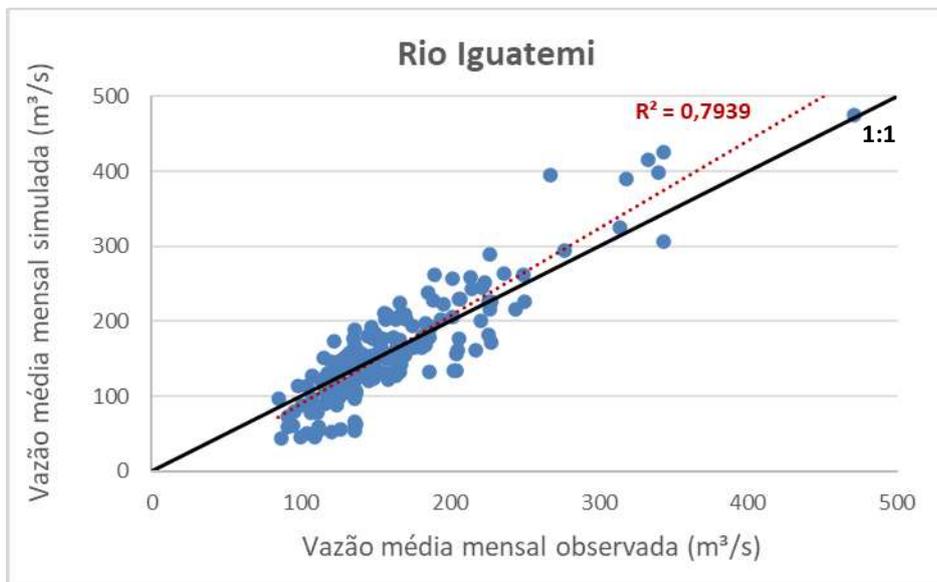


Figura 5.11 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia do rio Iguatemi.

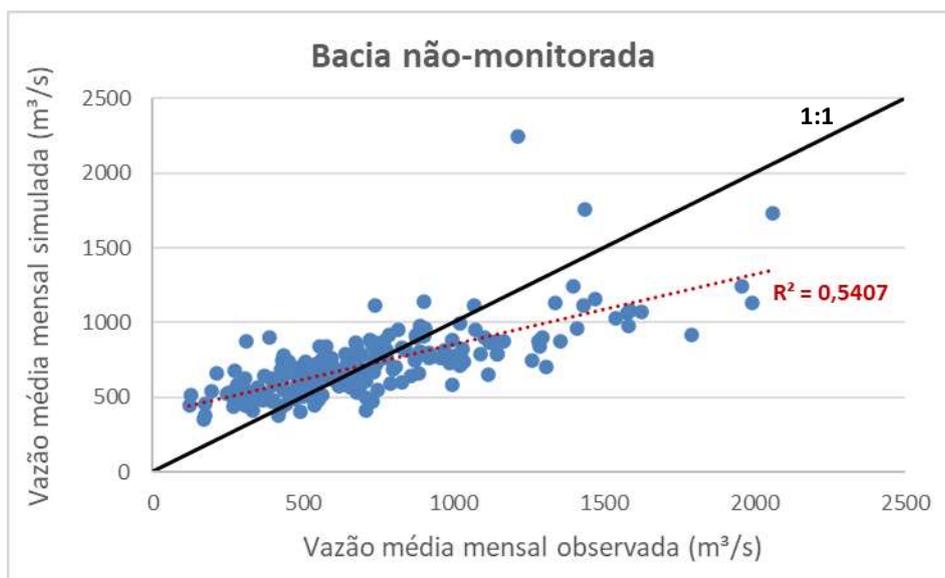


Figura 5.12 - Correlação entre as vazões médias mensais observadas e simuladas, para a sub-bacia “não-monitorada”.

Observa-se que, para as sub-bacias do rio Piquiri (Figura 5.7) e Ivaí (Figura 5.8), o modelo tende a superestimar as vazões mínimas e subestimar as vazões máximas, mas há um bom ajuste para as vazões médias. Isso indica uma dificuldade do modelo em representar a recessão e os picos dos hidrogramas, mas uma boa representação dos patamares médios de vazão de ambas sub-bacias.

Já para a sub-bacia do rio Iguatemi (Figura 5.11) ocorre o oposto: o modelo tende a subestimar as vazões mínimas e superestimar as vazões máximas, mas também há uma boa representação das vazões médias da bacia.

Para a sub-bacia do rio Ivinhema (Figura 5.9), há um bom ajuste para as vazões mínimas, mas o modelo tende a subestimar as vazões simuladas à medida em que o valor das vazões observadas aumenta. Nesse sentido, o modelo representa bem a recessão do hidrograma, mas não apresenta boa resposta aos aumentos de vazões dessa sub-bacia, o que fica evidente nos hidrogramas da Figura 5.3, principalmente nos anos anteriores a 2011.

Para a sub-bacia do rio Amambaí (Figura 5.10), o modelo indicou um ótimo ajuste das vazões simuladas para todos os patamares de vazão observada, e conseqüentemente um alto valor do coeficiente de determinação ($R^2 = 0,8735$).

Por fim, para a sub-bacia “não-monitorada” (Figura 5.12), percebe-se um indício de existência de viés entre as vazões simuladas e observadas, para todos os patamares de vazão.

Ademais, realizou-se uma análise dos erros residuais relativos das vazões simuladas de cada sub-bacia. Primeiramente, foi avaliada a evolução temporal desses erros, assim como seu valor médio para o período, conforme mostram os gráficos da Figura 5.13 até a Figura 5.18. Para o cômputo deste valor, foram desconsiderados os 10 primeiros meses de aquecimento do modelo.

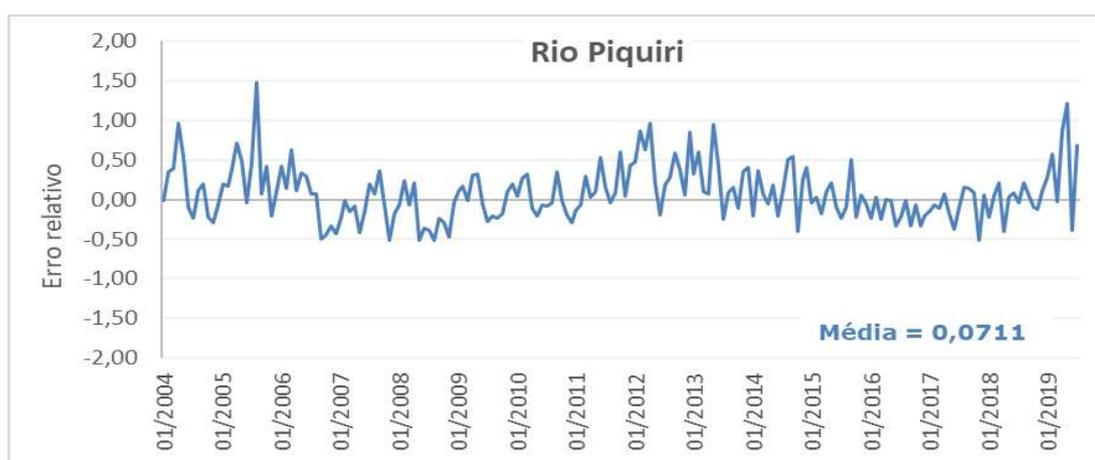


Figura 5.13 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Piquiri.

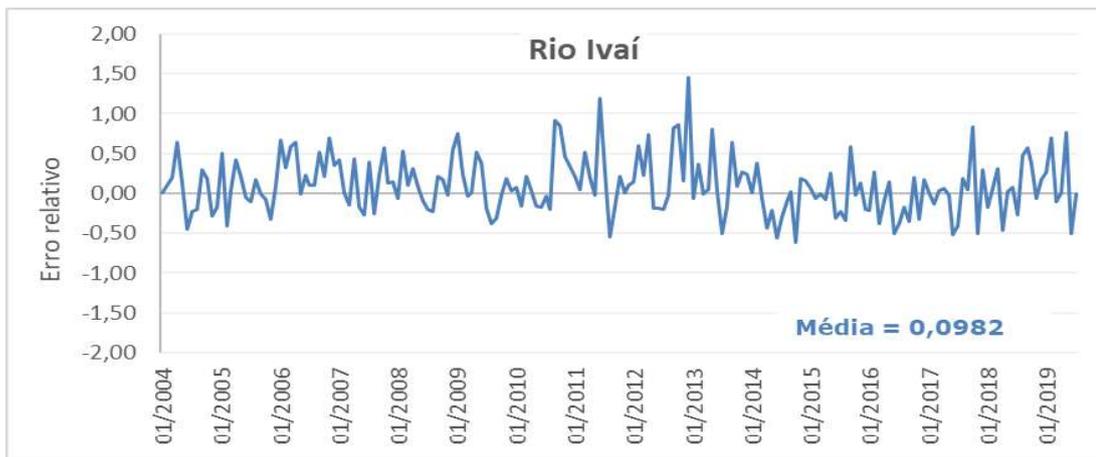


Figura 5.14 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Ivaí.

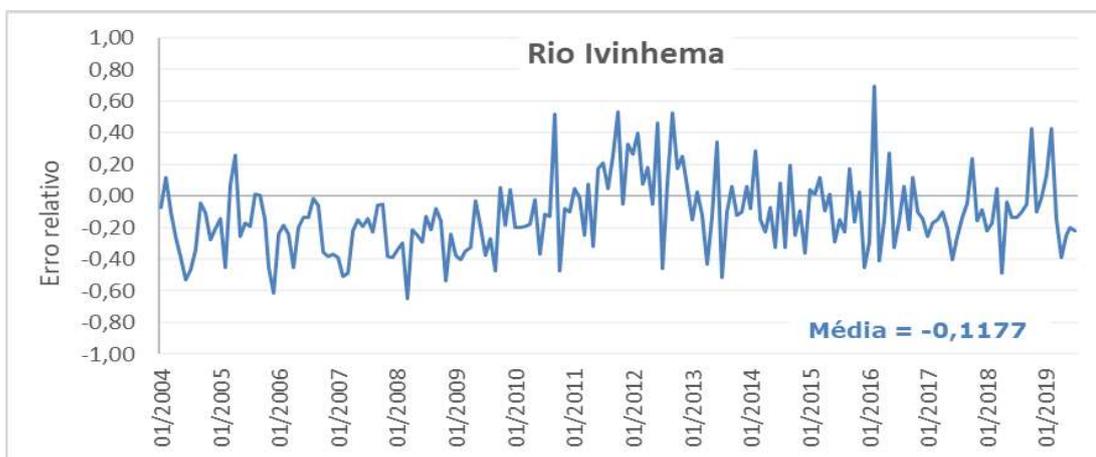


Figura 5.15 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Ivinhema.

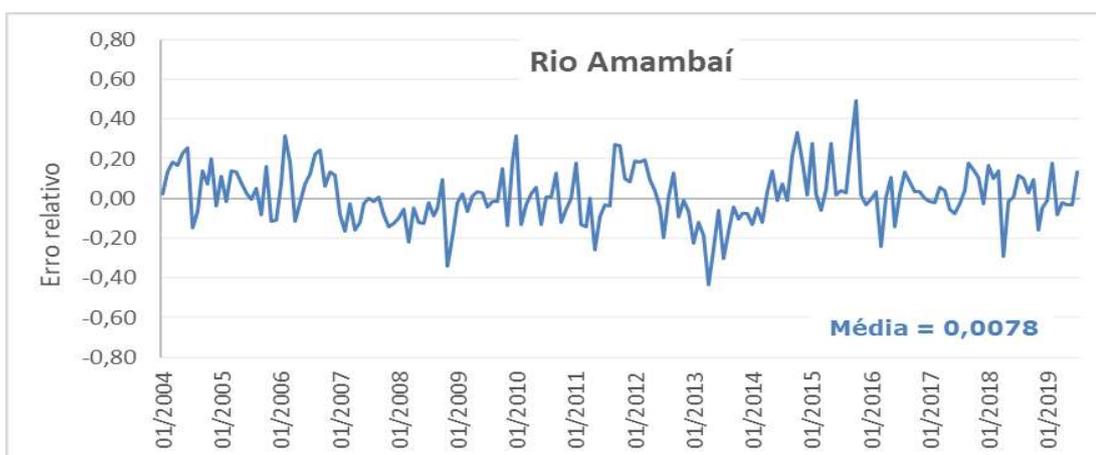


Figura 5.16 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Amambaí.

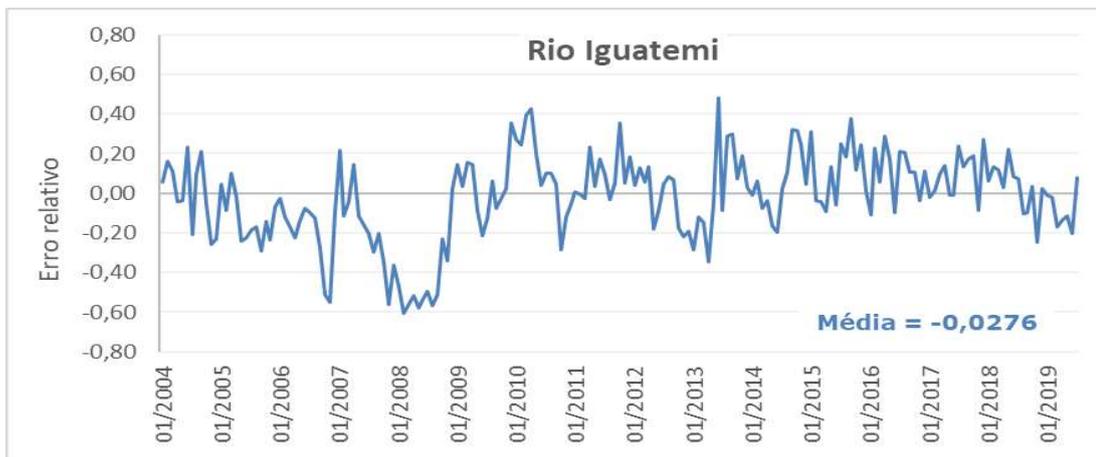


Figura 5.17 - Evolução temporal do erro relativo da simulação, para a sub-bacia do rio Iguatemi.

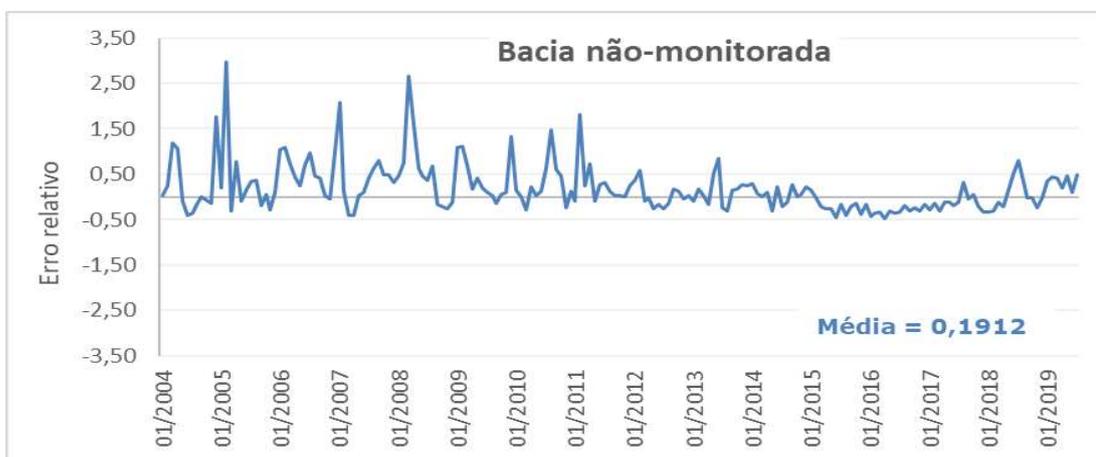


Figura 5.18 - Evolução temporal do erro relativo da simulação, para a sub-bacia “não-monitorada”.

A análise qualitativa dos gráficos permite concluir que não há mudança de tendência nos erros das sub-bacias dos rios Piquiri, Ivaí e Amambá ao longo do período simulado. No entanto, para as sub-bacias dos rios Ivinhema e Iguatemi, percebe-se uma alteração dessa tendência a partir do ano de 2011, reforçando a hipótese de inconsistências nos dados observados nos anos anteriores a este. Além disso, destaca-se a redução dos erros da simulação da sub-bacia “não-monitorada” ao longo do tempo, podendo também ser um indicativo de inconsistências nas séries utilizadas na estimativa de suas vazões observadas nos primeiros anos do período.

Além da evolução temporal, foi avaliado o cumprimento dos princípios de independência, homoscedasticidade e normalidade dos erros (ou resíduos) após a calibração do modelo. Para tanto, foram analisados os gráficos ilustrados na Figura 5.19 até a Figura 5.24.

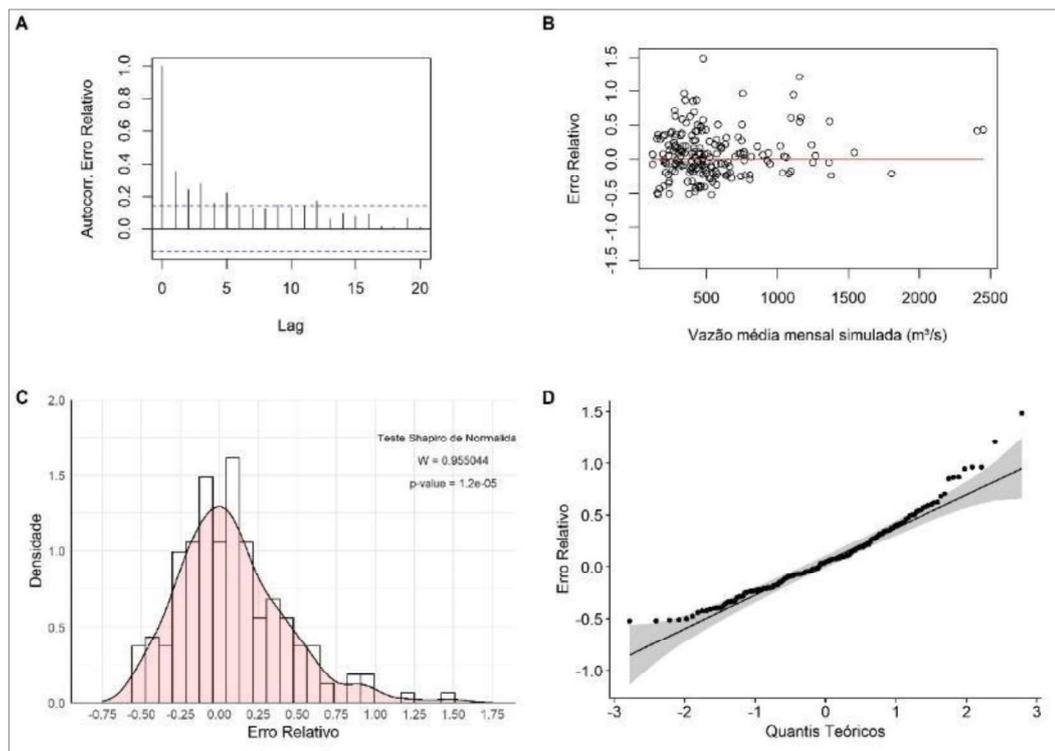


Figura 5.19 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Piquiri.

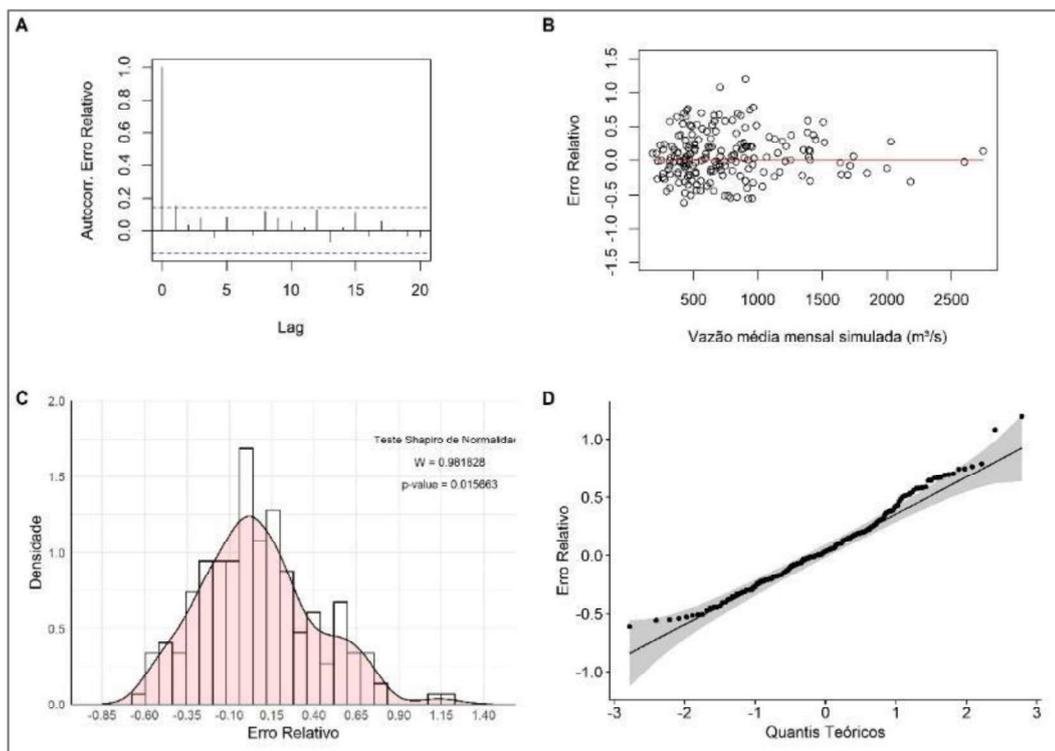


Figura 5.20 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Ivaí.

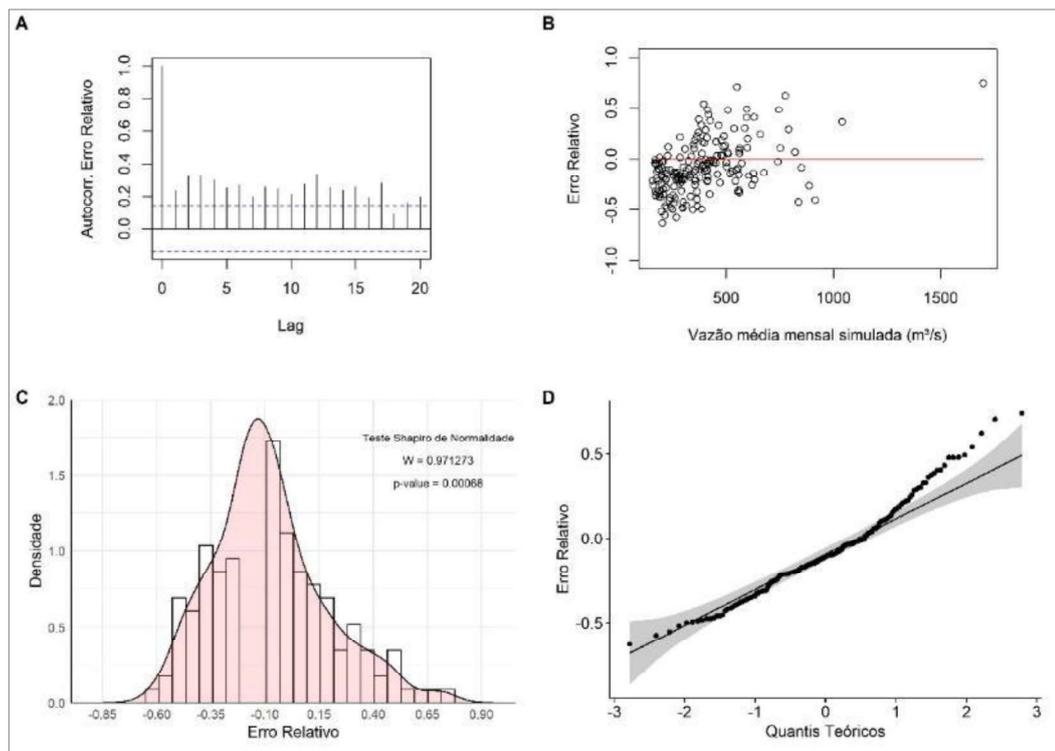


Figura 5.21 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Ivinhema.

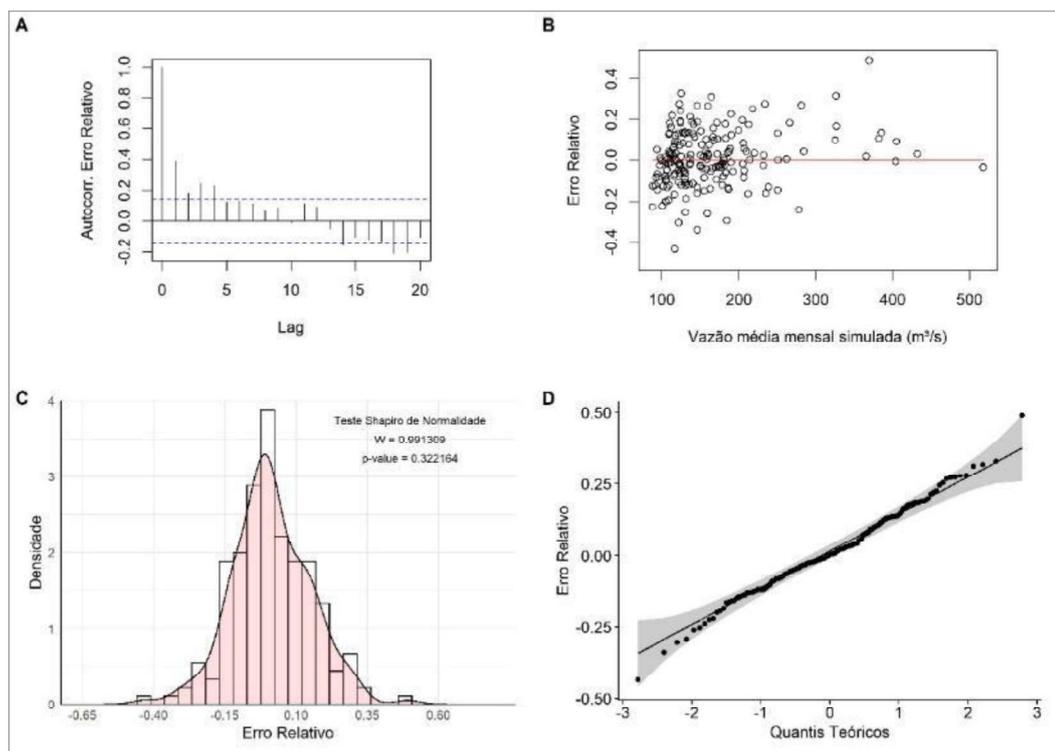


Figura 5.22 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Amambaí.

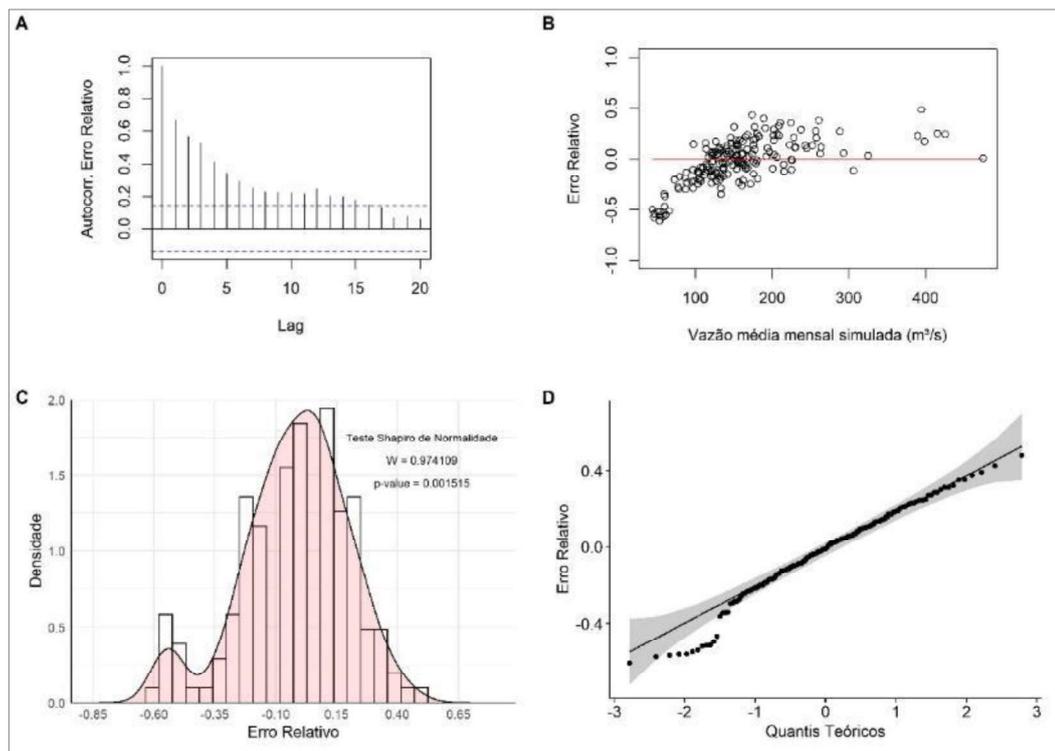


Figura 5.23 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia do rio Iguatemi.

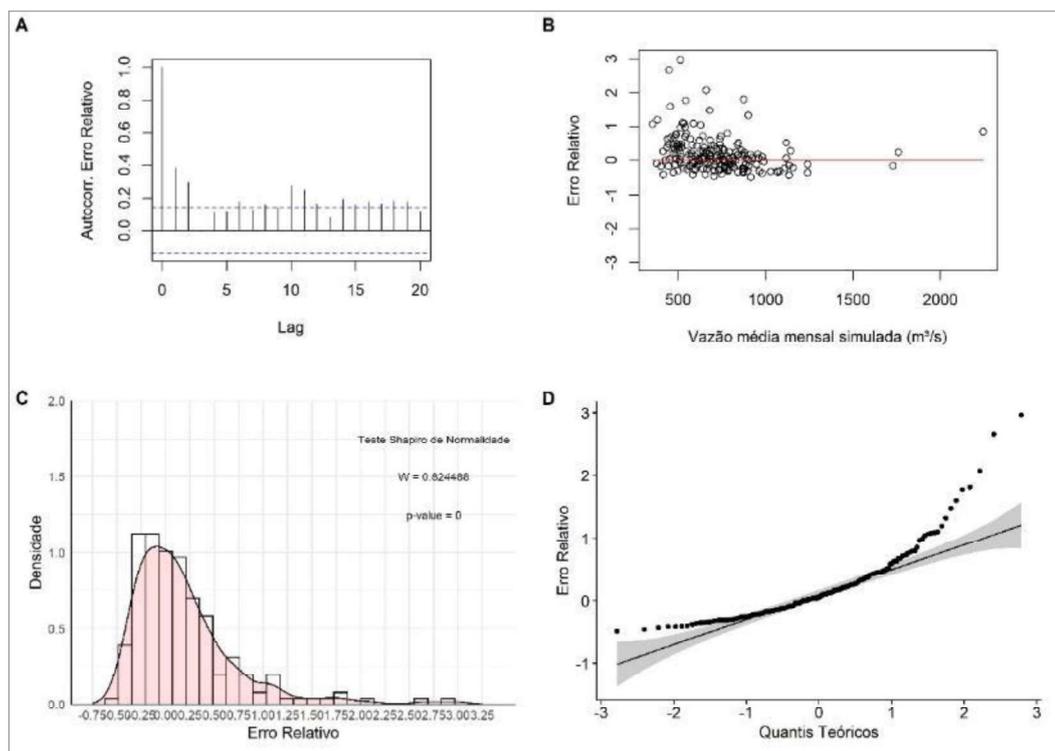


Figura 5.24 - Análise dos erros relativos: (A) autocorreção, (B) dispersão em relação à vazão simulada, (C) histograma e densidade de probabilidade, e (D) gráfico Quantil-Quantil da distribuição Normal, para sub-bacia “não-monitorada”.

Analisando-se os gráficos indicados pela letra “A”, constata-se a existência de correlação temporal nos erros da simulação para quase todas as sub-bacias – exceto para a sub-bacia do rio Ivaí –, e essa correlação é maior nas sub-bacias dos rios Ivinhema e Iguatemi e na sub-bacia “não-monitorada”.

Os gráficos indicados pela letra “B” mostram que as variâncias dos erros relativos são afetadas pela magnitude das vazões simuladas em todas as sub-bacias, algumas em maior proporção do que em outras.

Já os gráficos indicados pelas letras “C” (histograma e função densidade de probabilidade) e “D” (Quantil-Quantil da distribuição Normal), assim como os resultados do Teste de Normalidade Shapiro (SHAPIRO e WILK, 1965) apresentados nos gráficos “C”, permitem avaliar que apenas os resíduos da sub-bacia do rio Amambaí podem ser considerados normalmente distribuídos, a um nível de significância de 5%.

Assim, de maneira geral, os princípios de independência, homoscedasticidade e normalidade dos resíduos não foram verificados após a calibração do modelo para as sub-bacias modeladas. De fato, os trabalhos de Silva et al. (2014) e Silva (2015) reportam que a violação dessas premissas é bastante frequente nas aplicações de modelagem hidrológica, conforme discorrido no Capítulo de Revisão da Literatura do presente documento.

5.1.2 Calibração pelo método GLUE

A utilização do GLUE para a calibração do SMAP e estimação das incertezas preditivas foi bastante oportuna, no sentido de que o método não pressupõe a definição de um modelo probabilístico para os erros residuais a priori e uma vez que, na calibração convencional do modelo, foi identificada a violação das suposições tradicionais para os erro residuais (independência, homocedasticidade e normalidade).

Assim, o GLUE foi aplicado para cada uma das sub-bacias modeladas adotando-se, a priori, o valor de 0,60 como limite de corte para separar os conjuntos de parâmetros comportamentais dos não comportamentais, conforme metodologia anteriormente descrita.

Percebeu-se uma coerência entre o número de conjuntos de parâmetros comportamentais encontrados e o desempenho (coeficiente de Nash-Sutcliffe) para cada sub-bacia obtido na

calibração convencional: aquelas que apresentaram maiores valores de NSE tenderam a aceitar um maior número de conjunto de parâmetros a posteriori, após o “filtro” da medida de verossimilhança. É importante destacar que essa não é uma relação linear, devido ao caráter aleatório do método.

Em função disso, a aplicação do GLUE para as bacias do rio Ivinhema e “não-monitorada” não gerou nenhum conjunto de parâmetros comportamentais, uma vez que o limite de corte estabelecido a priori para a medida da verossimilhança (0,60) é um valor superior àqueles encontrados na calibração manual (0,46 e 0,52, respectivamente). Diante dessa constatação, para as referidas sub-bacias os valores desses limites foram alterados para 0,40 e 0,50, respectivamente, de forma a viabilizar a obtenção de resultados para as mesmas.

Uma vez aplicado o GLUE para cada sub-bacia modelada, foram contabilizados os conjuntos de parâmetros comportamentais selecionados pelo método. Destes, extraíram-se as distribuições a posteriori para cada um de seus parâmetros (E2, K, CREC e SAT), e das simulações comportamentais resultantes, foram determinados os limites de incerteza de 95% (UL95). Os gráficos ilustrados na Figura 5.25 até a Figura 5.30 apresentam os resultados obtidos para cada sub-bacia.

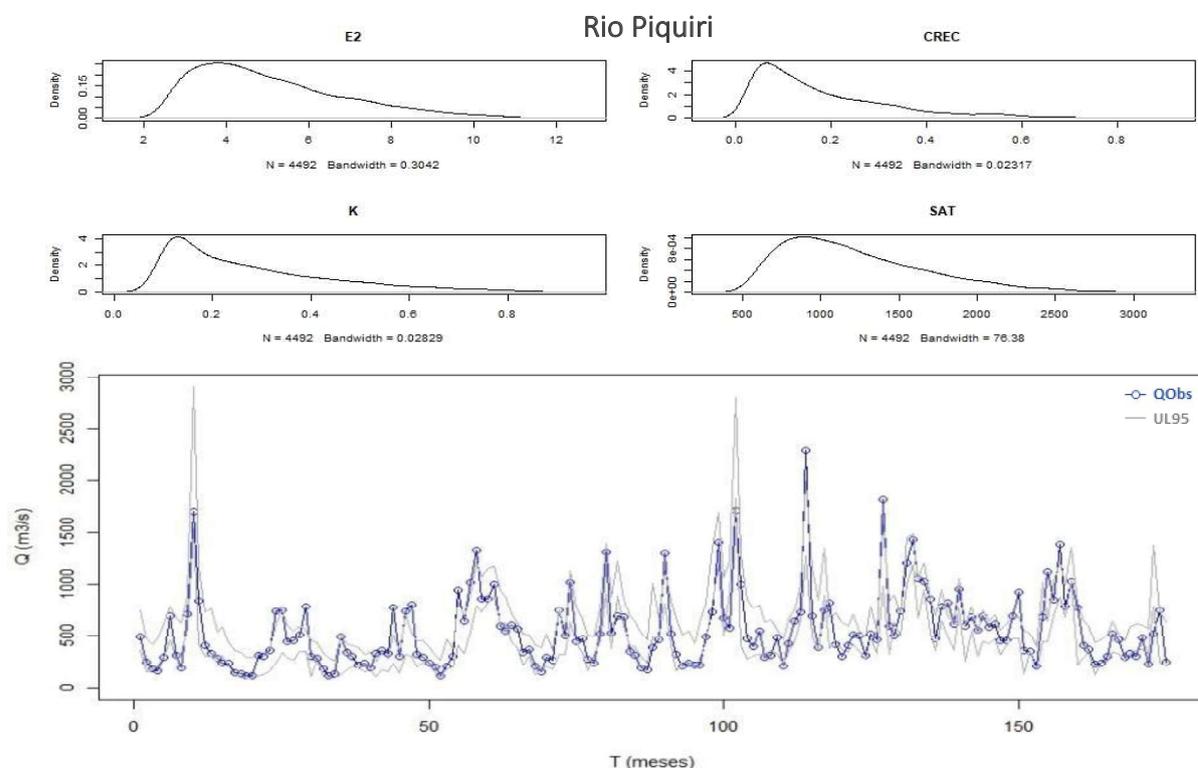


Figura 5.25 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Piquiri.

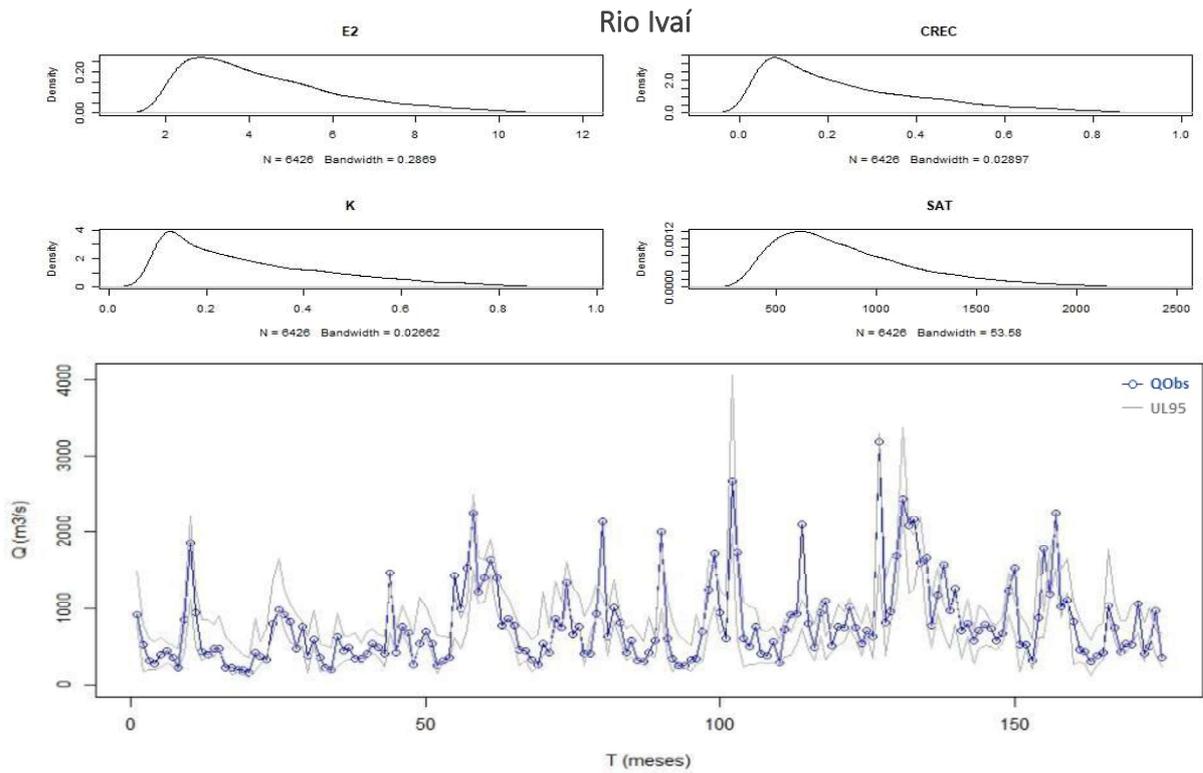


Figura 5.26 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Ivaí.

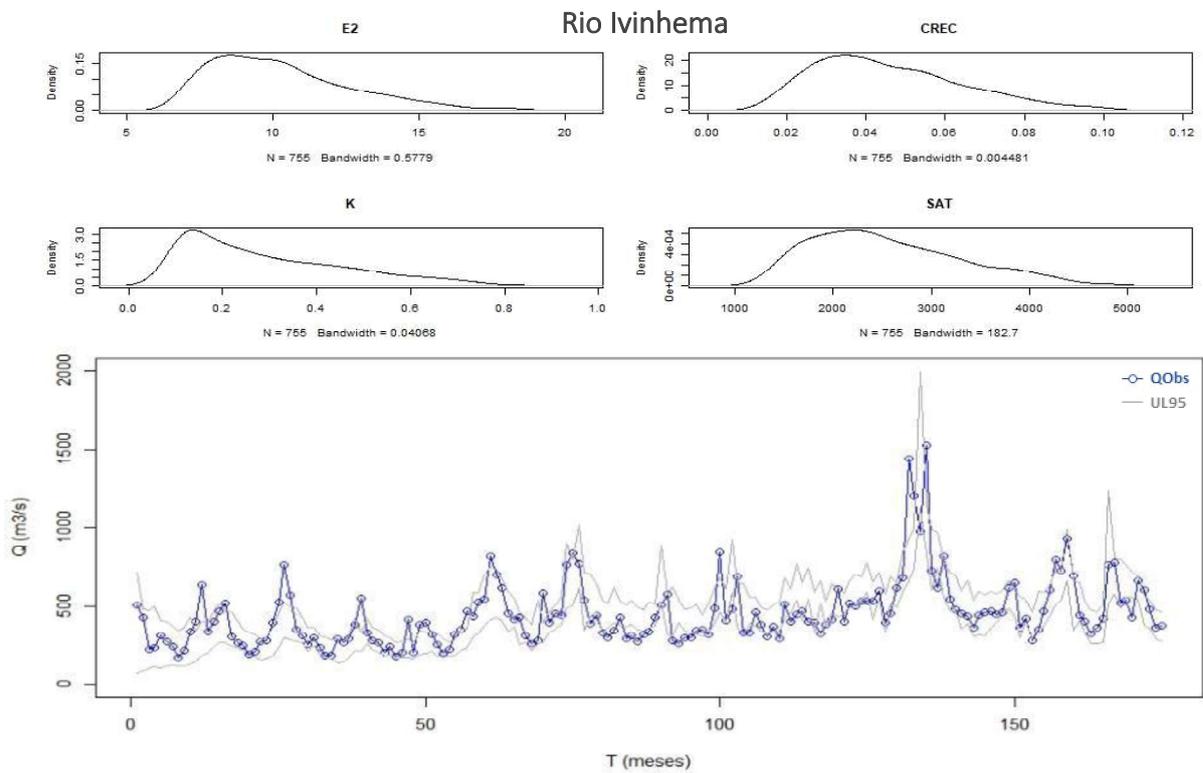


Figura 5.27 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Ivinhema.

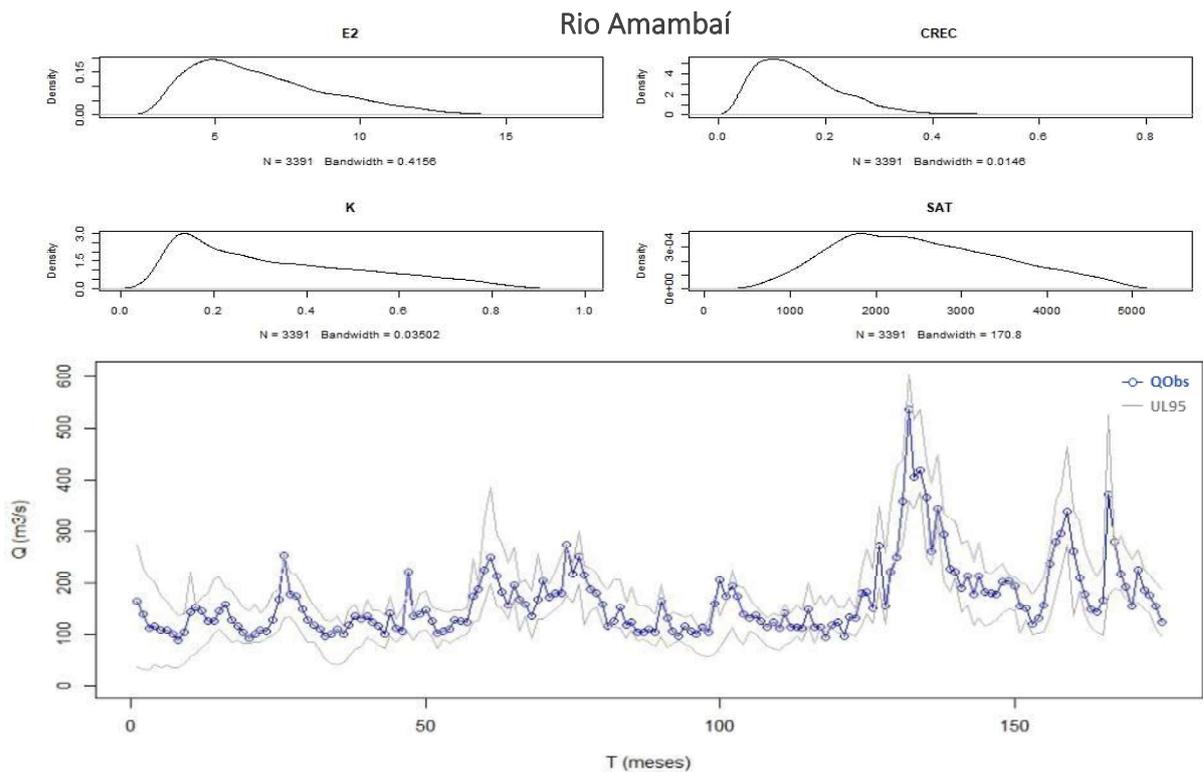


Figura 5.28 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Amambaí.

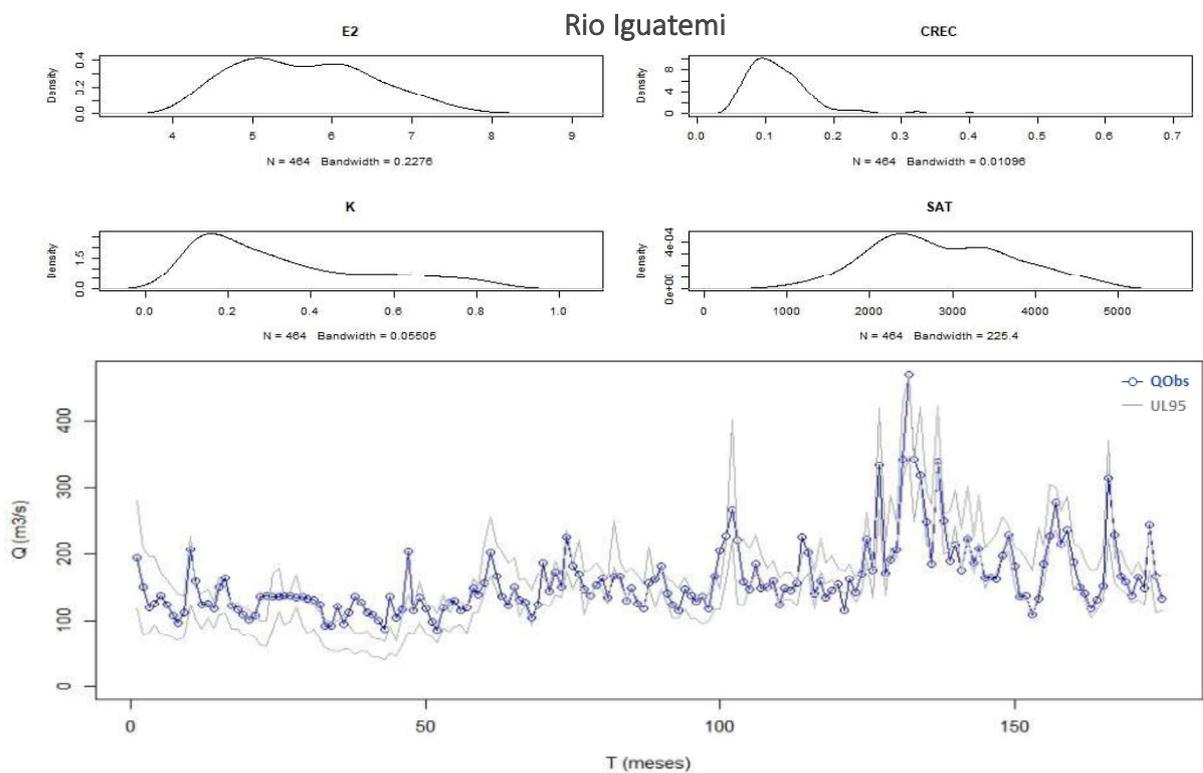


Figura 5.29 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia do rio Iguatemi.

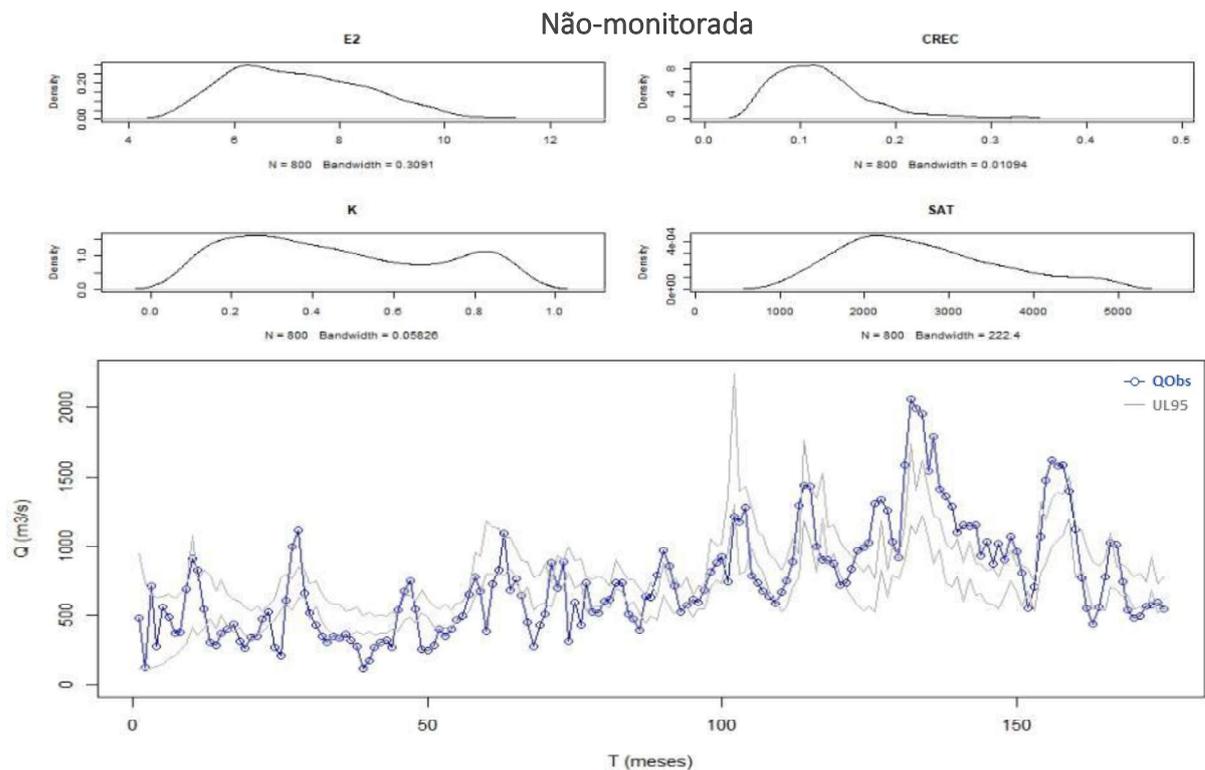


Figura 5.30 - Distribuições a posteriori dos parâmetros do SMAP e UL95 das simulações comportamentais, em relação à série de vazões observadas na sub-bacia “não-monitorada”.

Observa-se que os limites de incerteza calculados não conseguiram contemplar toda a variabilidade das séries observadas. Tal fato pode estar relacionado (i) à limitação estrutural do modelo SMAP na representação das vazões observadas; (ii) a inconsistências nas próprias séries de dados observados; e/ou (iii) ao próprio método GLUE, quanto à função da verossimilhança e ao seu limite de corte adotados. Em relação a este último ponto, Jin et al. (2010) destacam que os limites de incerteza resultantes do GLUE, assim como o percentual das séries observadas neles inseridas, são sensíveis aos limites de corte adotados para a função de verossimilhança.

Nesse sentido, das simulações comportamentais obtidas após a aplicação do GLUE, avaliou-se, para cada sub-bacia, o percentual de inserção das séries de vazões observadas nos respectivos limites de incerteza calculados, assim como o valor médio das vazões simuladas.

Os resultados obtidos encontram-se resumidos na Tabela 5.2. Ainda que de forma não totalmente linear, percebe-se uma forte relação entre o número de conjuntos de parâmetros comportamentais e o percentual de inserção das séries observadas nos UL's calculados.

Tabela 5.2 - Resultados da calibração pelo método GLUE para cada sub-bacia modelada.

Sub-bacia	Limite de corte verossimilhança	Nº conj. parâm. comportamentais	QS _{méd} (m ³ /s)	% de inserção das medições no UL95
Rio Piquiri	0,60	4.492	552,6	65,5
Rio Ivaí	0,60	6.426	760,9	79,3
Rio Ivinhema	0,40*	755	452,1	66,1
Rio Amambaí	0,60	3.391	166,4	92,0
Rio Iguatemi	0,60	464	159,0	62,6
Não-monitorada	0,50*	800	724,9	38,5

* Limites alterados para viabilizar a obtenção de resultados.

Ademais, de modo a se avaliar a interação paramétrica no SMAP, foram geradas as projeções bidimensionais da superfície de resposta da função de verossimilhança aos parâmetros do modelo, combinando-os dois a dois. Os gráficos obtidos para cada sub-bacia encontram-se ilustrados da Figura 5.31 até a Figura 5.36. Destes, é possível observar a complexidade da superfície de resposta da função verossimilhança (“NASH”), dado que seus maiores valores encontram-se em diferentes regiões dos gráficos, reiterando-se, assim, a ideia da equifinalidade e da existência de interação entre esses parâmetros. Pode-se também identificar, a partir da concentração dos pontos de maiores valores de Nash, os parâmetros para os quais o modelo é mais sensível (no caso, E2 e SAT).

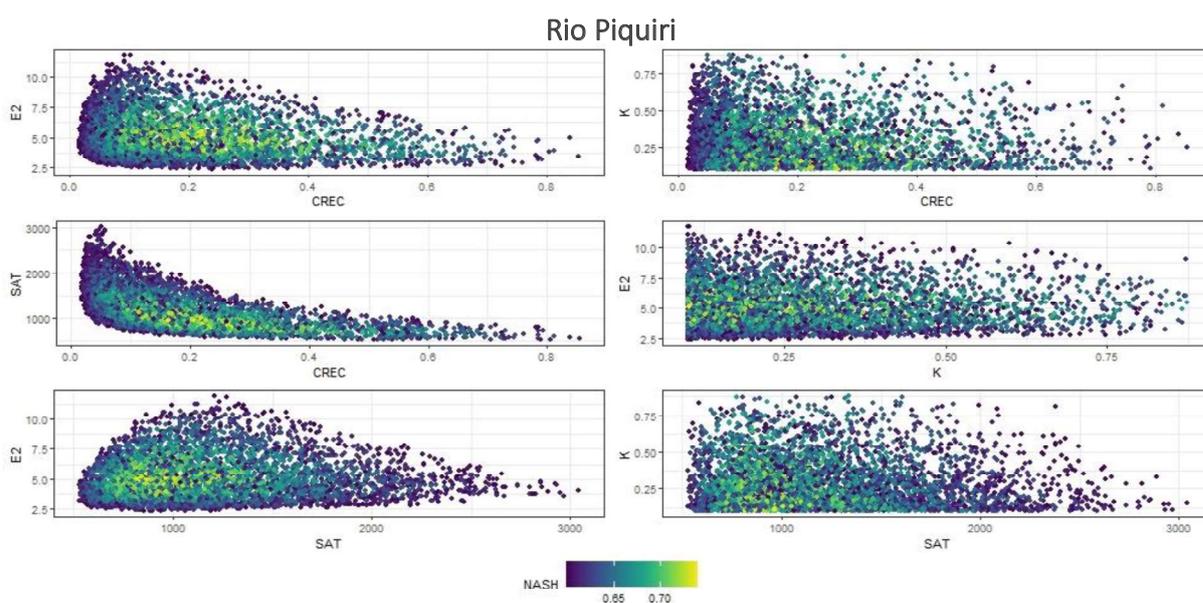


Figura 5.31 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Piquiri.

Rio Ivaí

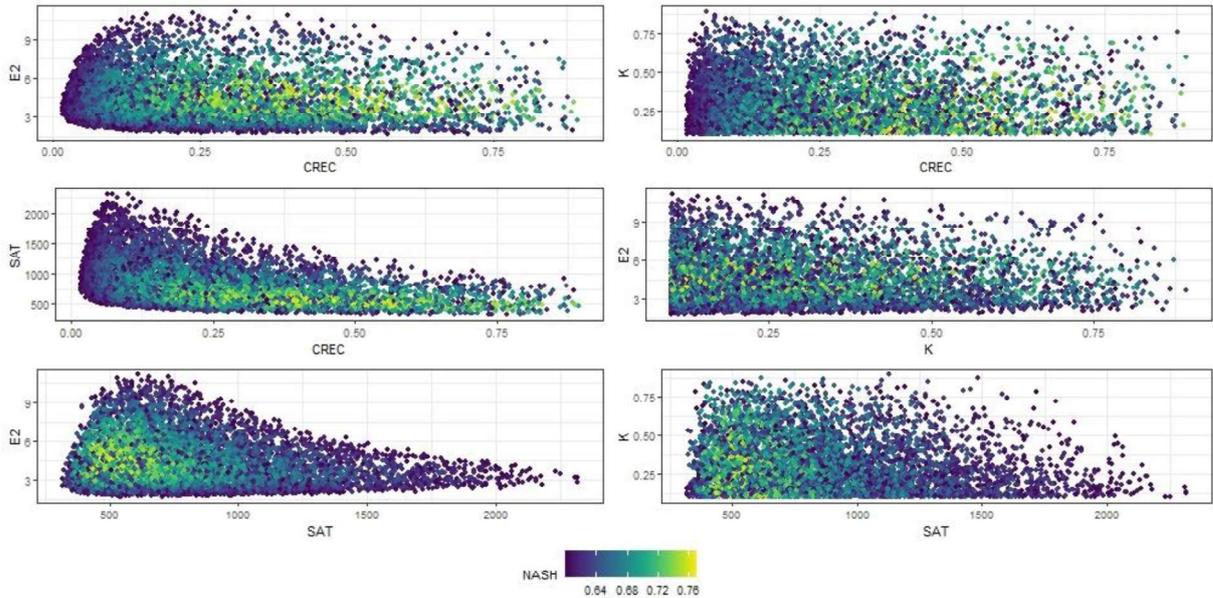


Figura 5.32 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Ivaí.

Rio Ivinhema

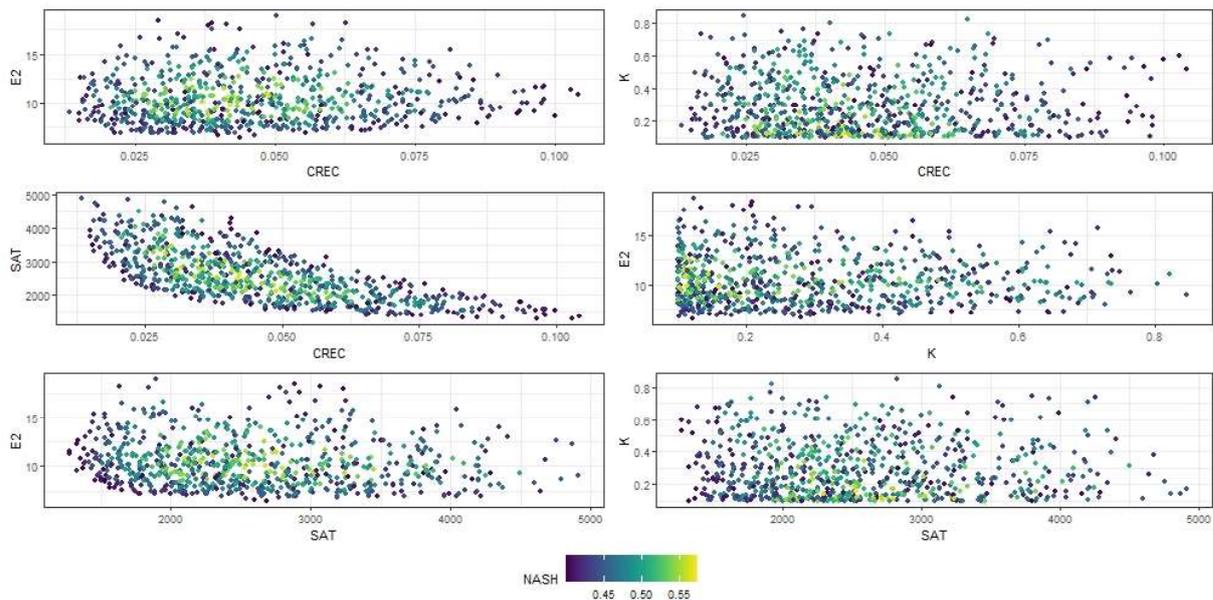


Figura 5.33 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Ivinhema.

Rio Amambaí

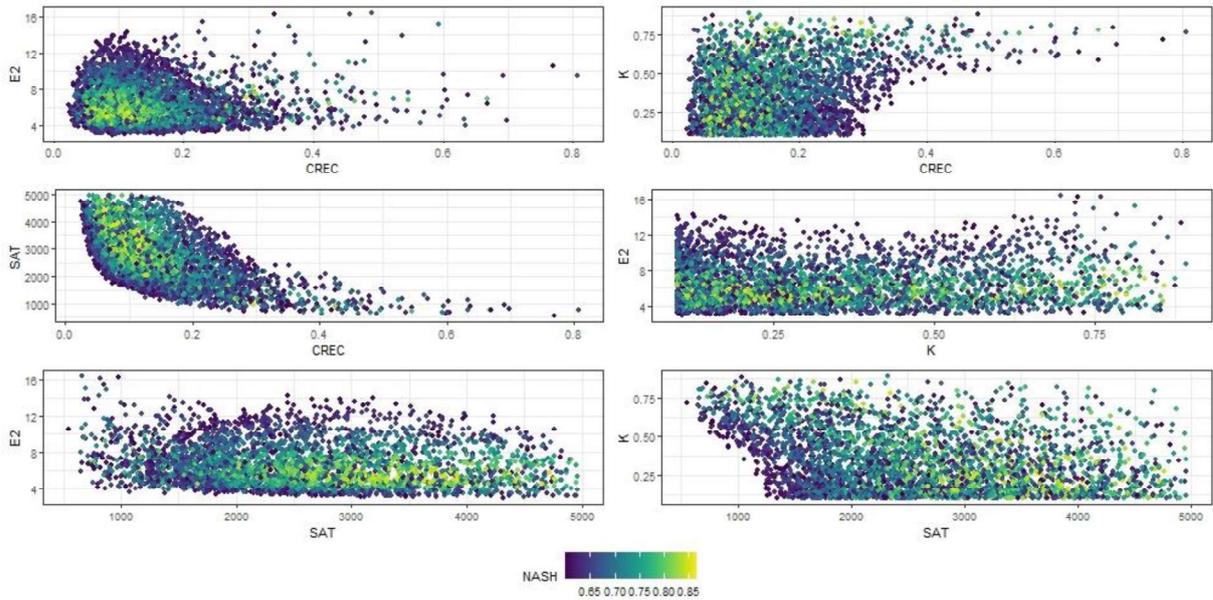


Figura 5.34 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Amambaí.

Rio Iguatemi

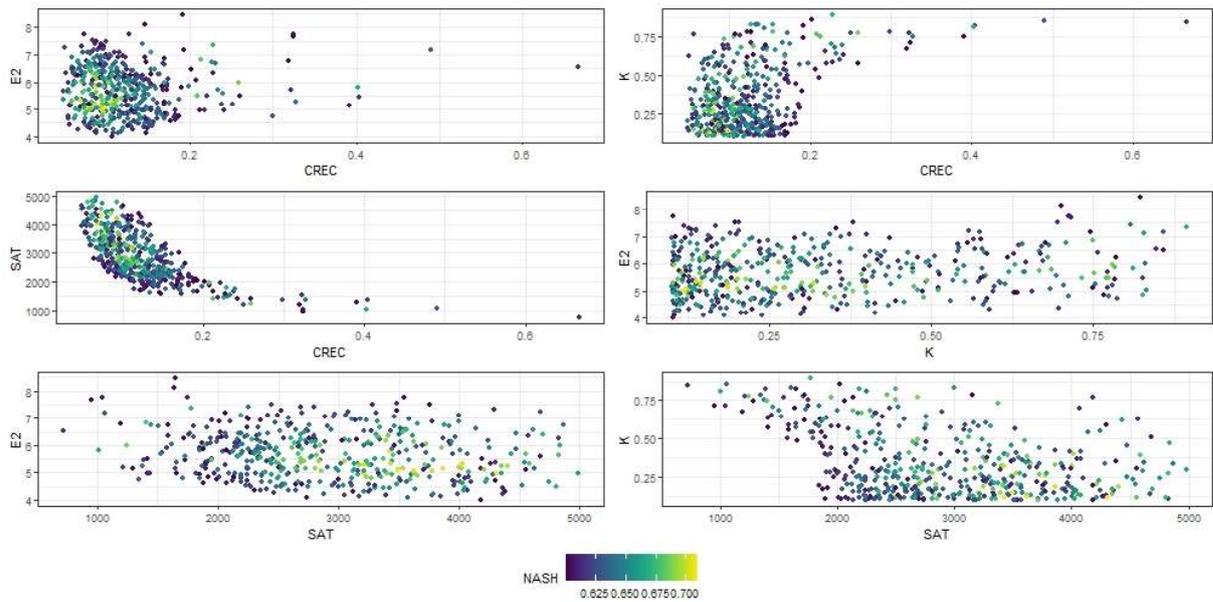


Figura 5.35 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia do rio Iguatemi.

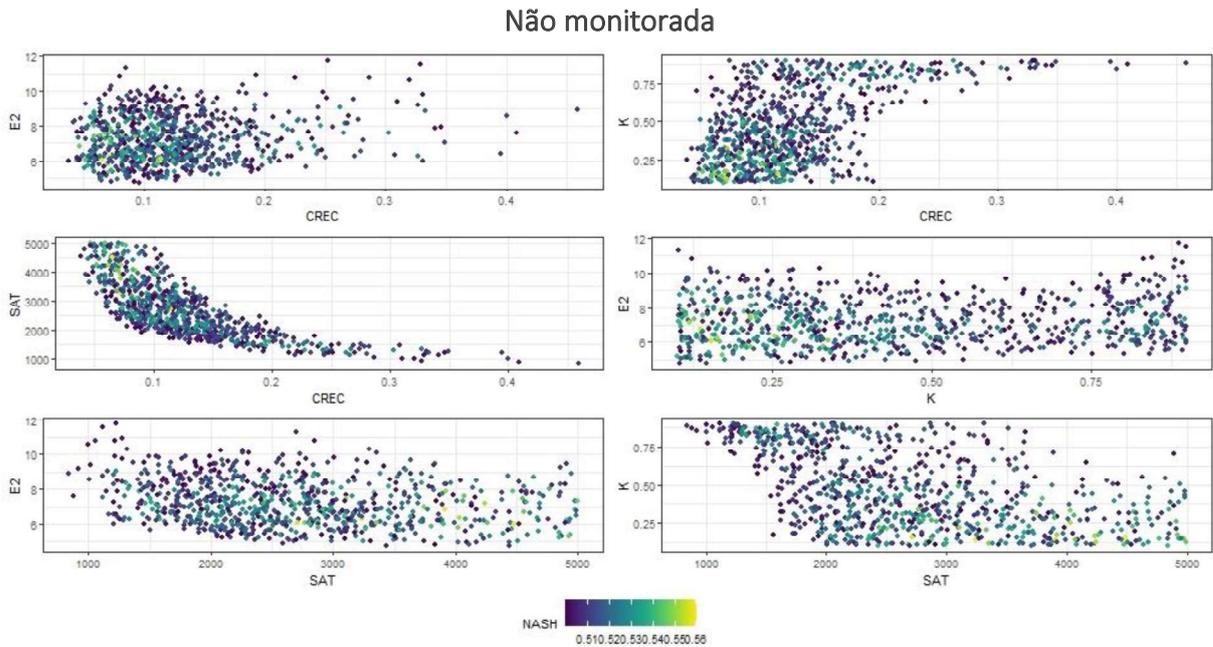


Figura 5.36 - Projeção bidimensional da superfície de resposta da função verossimilhança aos parâmetros do SMAP combinados dois a dois, para a sub-bacia “não-monitorada”.

Por fim, as medidas de verossimilhança (coeficientes NSE) dos conjuntos de parâmetros comportamentais retidos pelo método foram normalizadas por meio da Equação (4.6), obtendo-se assim os pesos $w_p^{\theta_i}$ associados a esses conjuntos.

5.2 Simulações ponderadas

Os pesos $w_p^{\theta_i}$ resultantes da calibração pelo GLUE foram então utilizados para ponderar as vazões simuladas por cada conjunto de parâmetros comportamentais, de cada sub-bacia, para o mesmo período da calibração. A partir das simulações ponderadas resultantes, foram calculadas as mesmas métricas da calibração convencional (MAE, MRE, RMSE e NSE).

Os resultados obtidos encontram-se resumidos na Tabela 5.3. Semelhantemente à calibração manual, os erros relativos médios estiveram abaixo dos 30% para todas as sub-bacias, exceto a “não-monitorada”. Além disso, as demais métricas obtidas possuem a mesma ordem de grandeza daquelas resultantes da avaliação da calibração convencional (Tabela 5.1).

Tabela 5.3 - Métricas globais calculadas a partir das simulações comportamentais ponderadas pelos pesos $w_p^{\theta_i}$.

Sub-bacia	MAE (m ³ /s)	MRE	RMSE (m ³ /s)	NSE
Rio Piquiri	137,5	0,2954	187,8	0,72
Rio Ivaí	184,5	0,2432	276,7	0,73
Rio Ivinhema	95,6	0,2227	136,4	0,55
Rio Amambaí	22,7	0,1485	34,7	0,74
Rio Iguatemi	25,3	0,1658	32,9	0,63
Não-monitorada	203,8	0,3657	255,3	0,56

Ademais, avaliou-se, mês a mês, a dispersão das vazões simuladas em relação às observadas, assim como do erro residual dessas simulações, em termos absolutos e relativos. Para tanto, foram analisados os gráficos ilustrados na Figura 5.37 até a Figura 5.42.

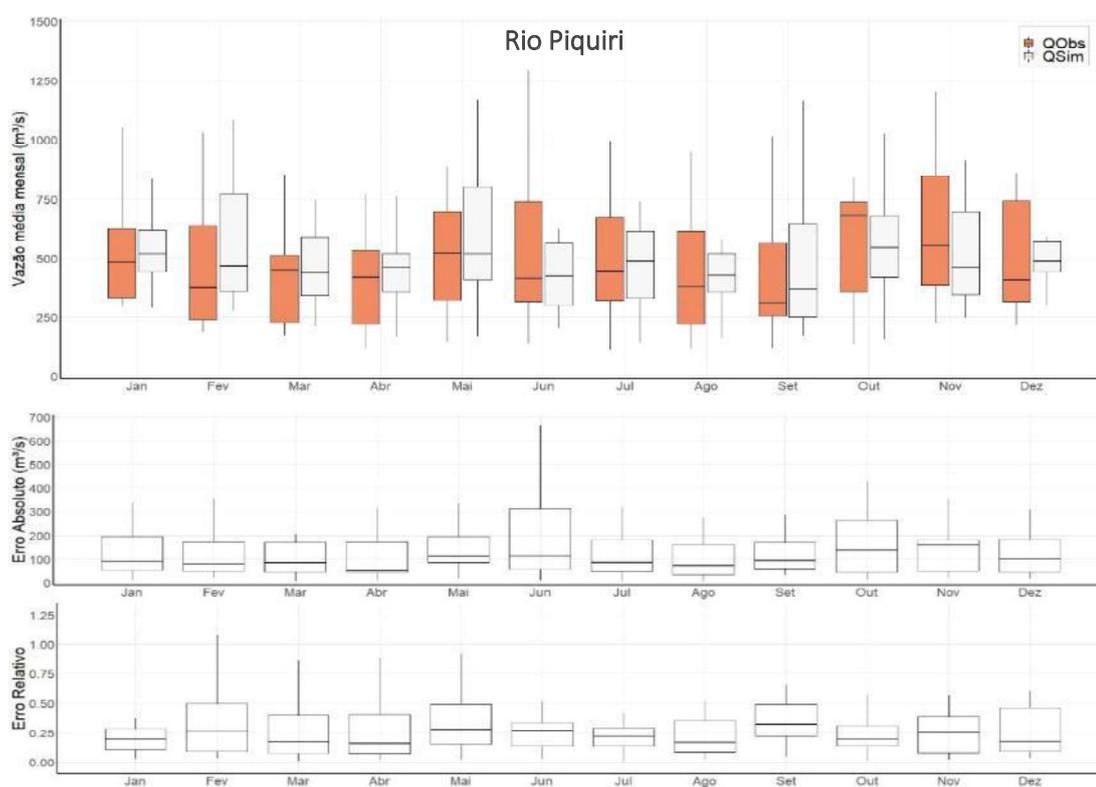


Figura 5.37 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Piquiri.

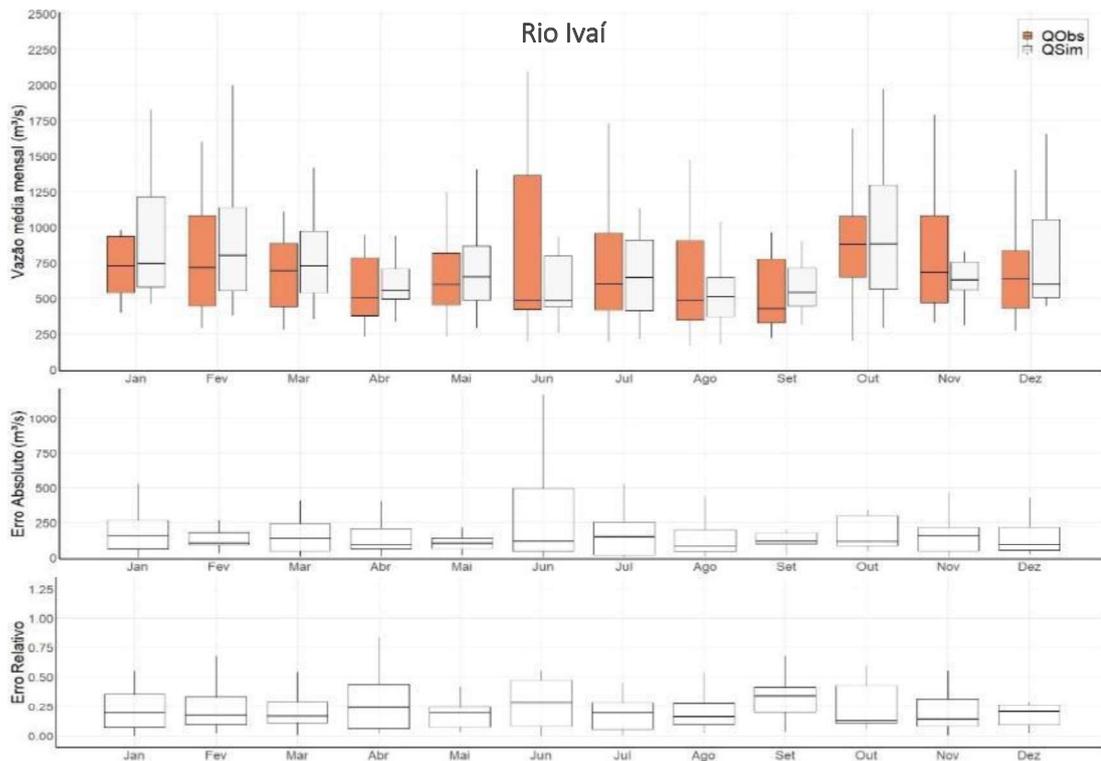


Figura 5.38 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Ivaí.

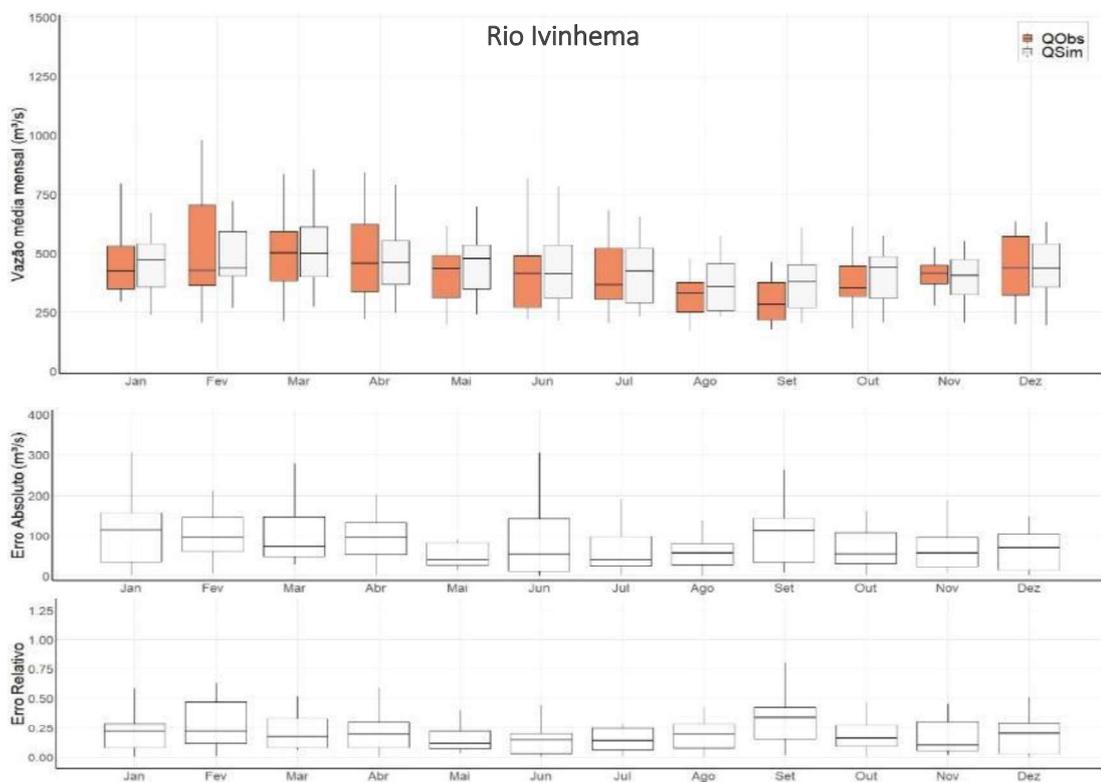


Figura 5.39 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Ivinhema.

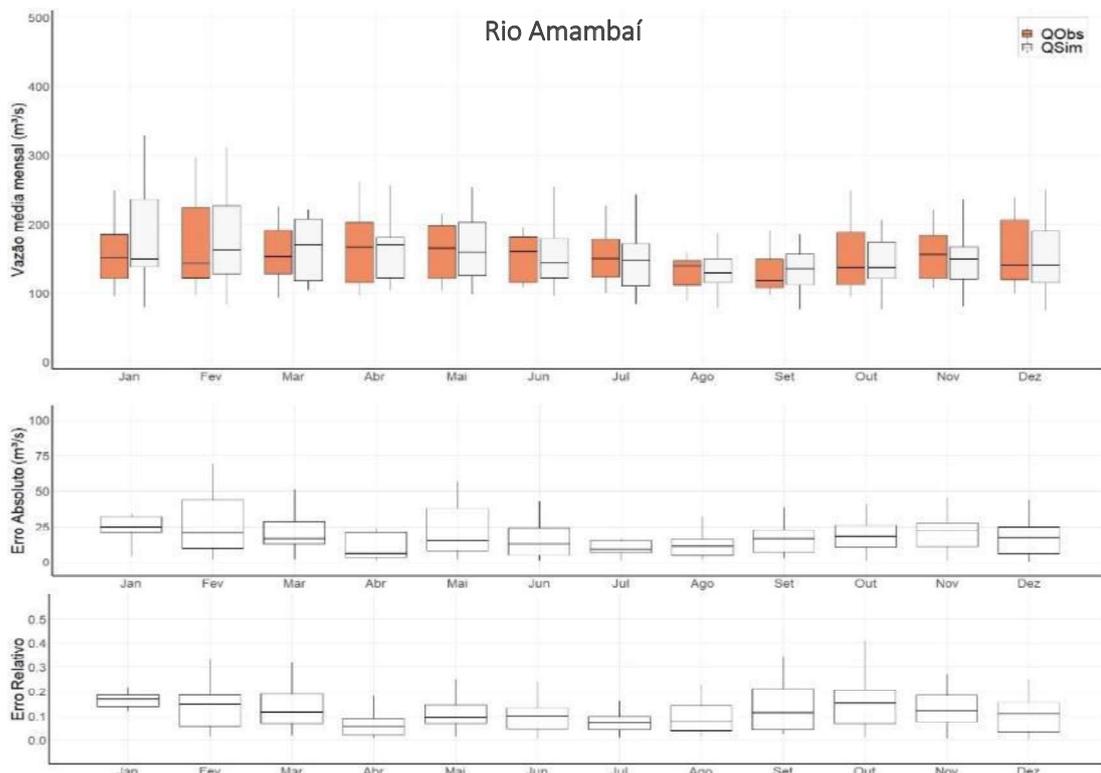


Figura 5.40 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Amambá.

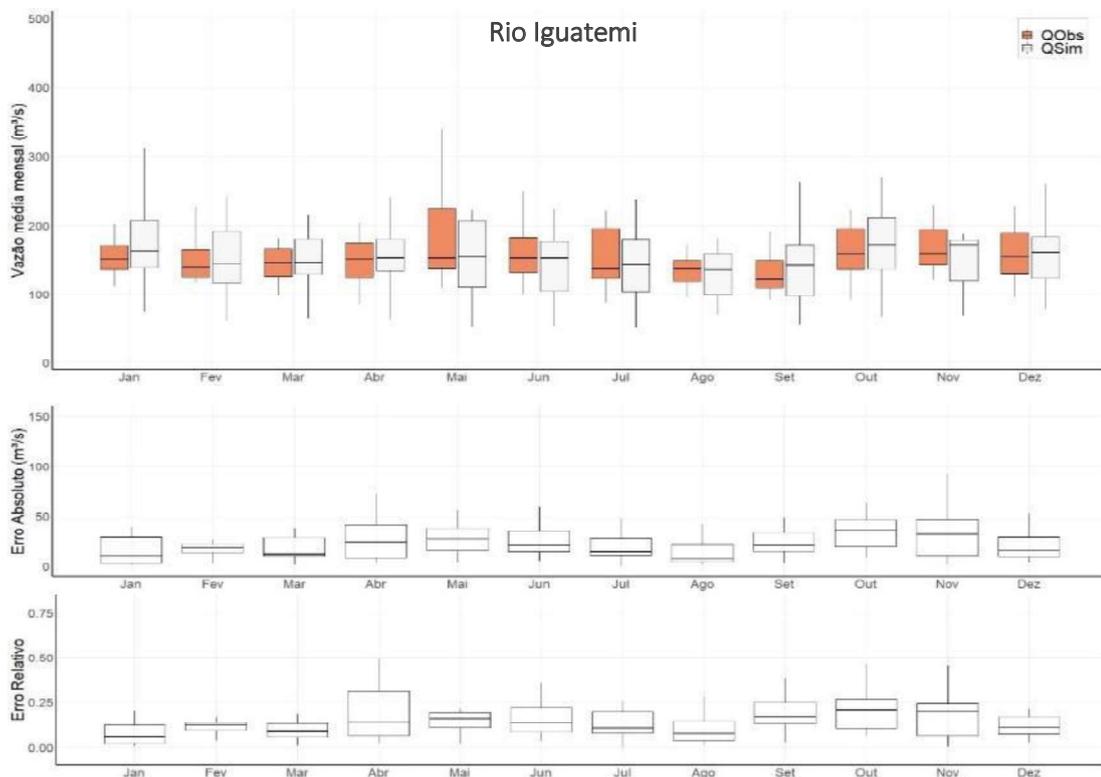


Figura 5.41 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia do rio Iguatemi.

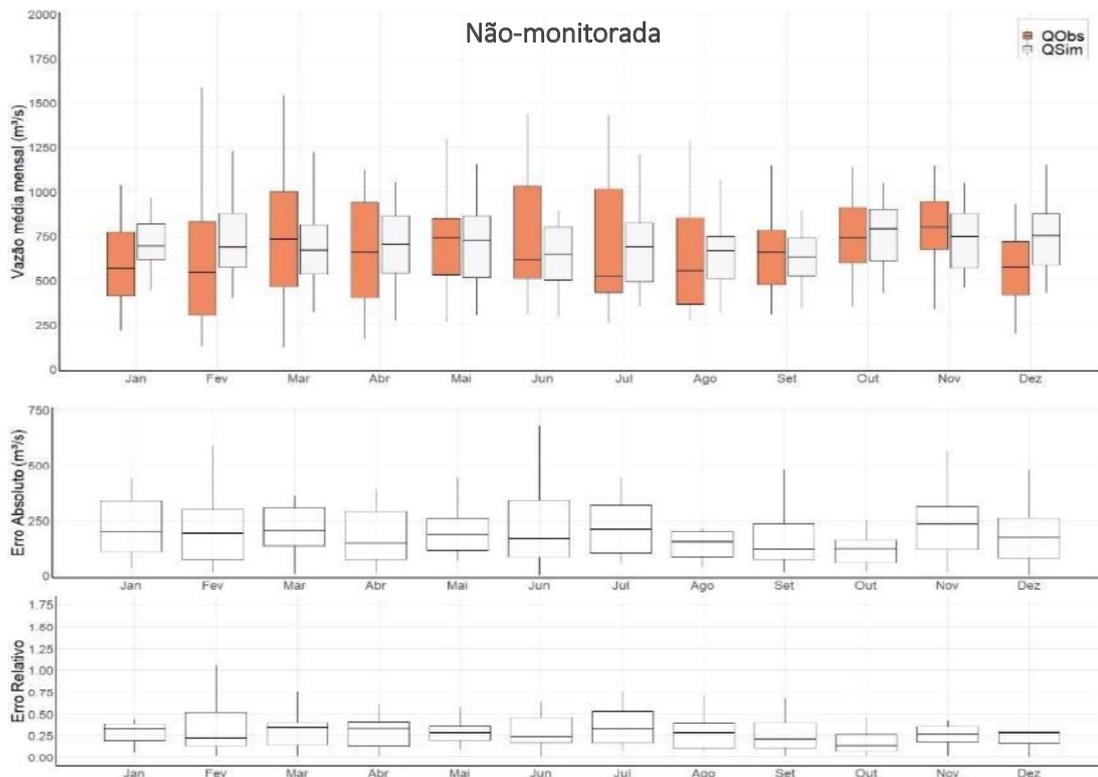


Figura 5.42 - Box-plots das vazões médias observadas e simuladas (ponderadas) e dos erros absolutos e relativos da simulação, mês a mês, para a sub-bacia “não-monitorada”.

A análise qualitativa dos gráficos não sugere nenhuma sazonalidade na capacidade preditiva do método (simulações do SMAP ponderadas pelos pesos $w_p^{\theta_i}$) em representar as vazões das sub-bacias modeladas. Em termos médios (mediana dos valores), as vazões são bem representadas em praticamente todos os meses do ano. No entanto, há dificuldades na representação da variabilidade dessas vazões ao longo de cada mês, mas não é possível detectar um padrão comum a todas as sub-bacias: em algumas, o método possui maior dificuldade em representar a variabilidade dos meses climatologicamente mais chuvosos; em outras, dos meses mais secos.

5.3 Previsão de vazões e incorporação de incertezas

5.3.1 Previsão de afluência à Itaipu

Conforme detalhado no Item 4.5.2.1 deste documento, para cada sub-bacia modelada foram gerados seus respectivos ESPs, a partir das previsões climáticas de precipitação do C3S/SEAS5 e da ponderação pelos pesos $w_p^{\theta_i}$ resultantes da etapa de calibração pelo GLUE. Os resultados obtidos em cada sub-bacia para cada uma das 12 séries de precipitação prevista avaliadas encontram-se ilustrados no APÊNDICE A.

A partir da amostragem por de simulações MC, foram realizadas 10^6 combinações das previsões dos ESPs obtidos, para cada série de precipitação prevista. Como resultado, foram obtidas 10^6 possíveis trajetórias para a afluência prevista à Itaipu, das quais foram calculados alguns quantis de interesse: o primeiro, segundo e terceiro quartis, os quantis $Q_{0,10}$ e $Q_{0,90}$ e os envelopes dos valores máximos e mínimos para cada mês de previsão.

Os gráficos da Figura 5.43 até a Figura 5.54 ilustram esses resultados. Neles, podem ser visualizadas as séries de afluências mensais observadas dos últimos 18 meses (linha sólida com pontos); a mediana, como medida de tendência central das simulações e das previsões (linha tracejada); e os limites de incerteza UL_{50} , UL_{80} e envelopes (máximos e mínimos) das previsões (áreas hachuradas).

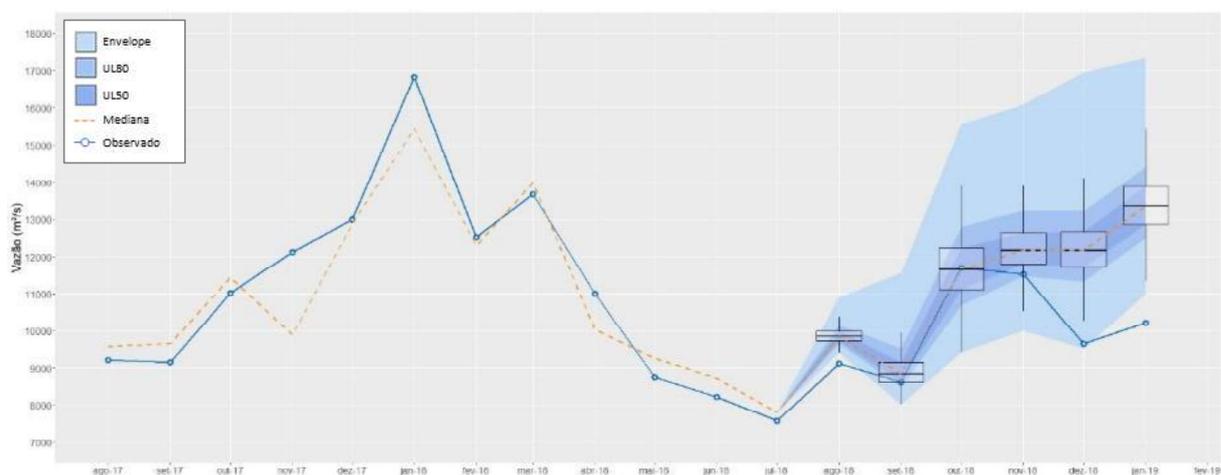


Figura 5.43 - Série de afluências observadas e simuladas e previsão probabilística das afluências à UHE Itaipu, para a previsão de precipitação iniciada em agosto/2018.

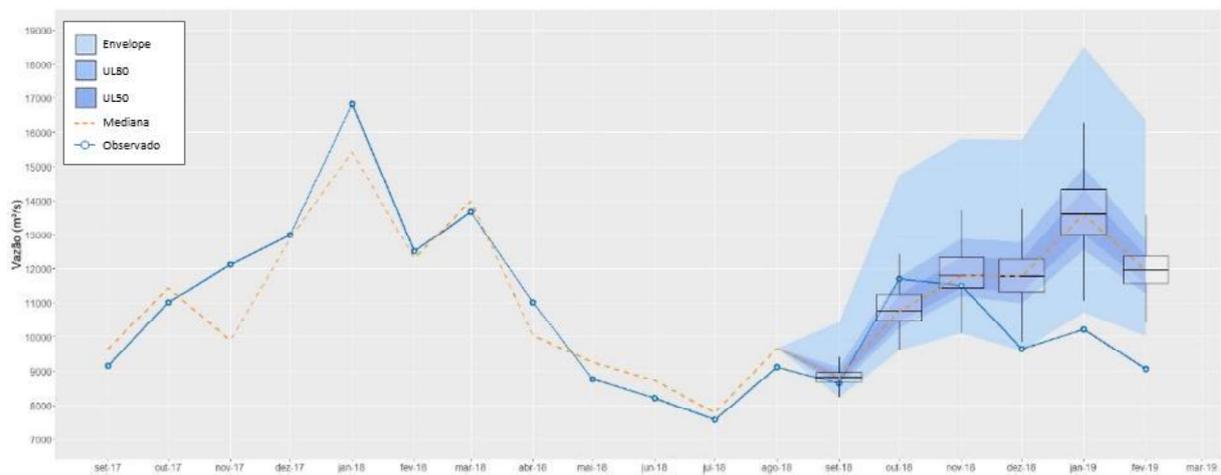


Figura 5.44 - Série de afluências observadas e simuladas e previsão probabilística das afluências à UHE Itaipu, para a previsão de precipitação iniciada em setembro/2018.

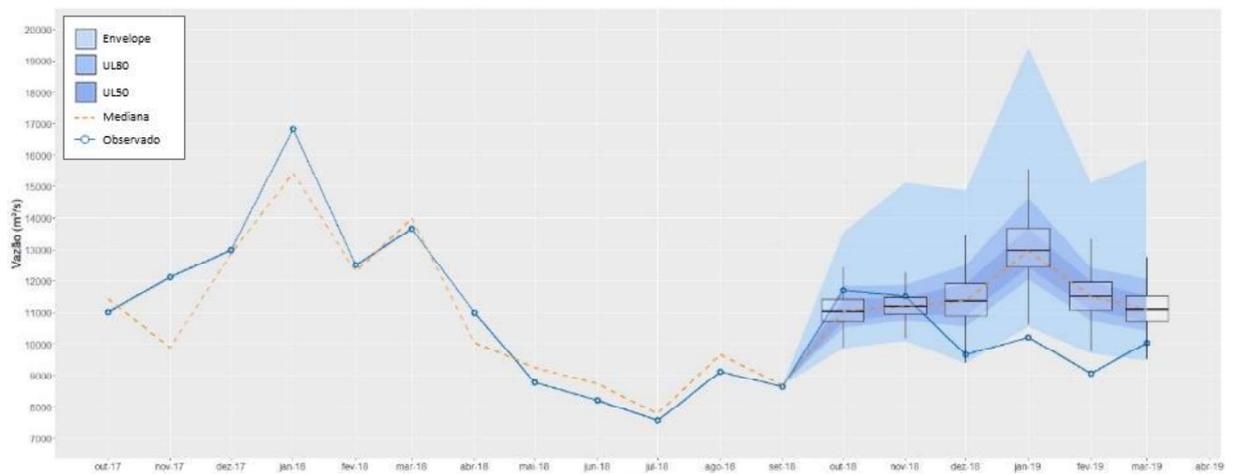


Figura 5.45 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em outubro/2018.

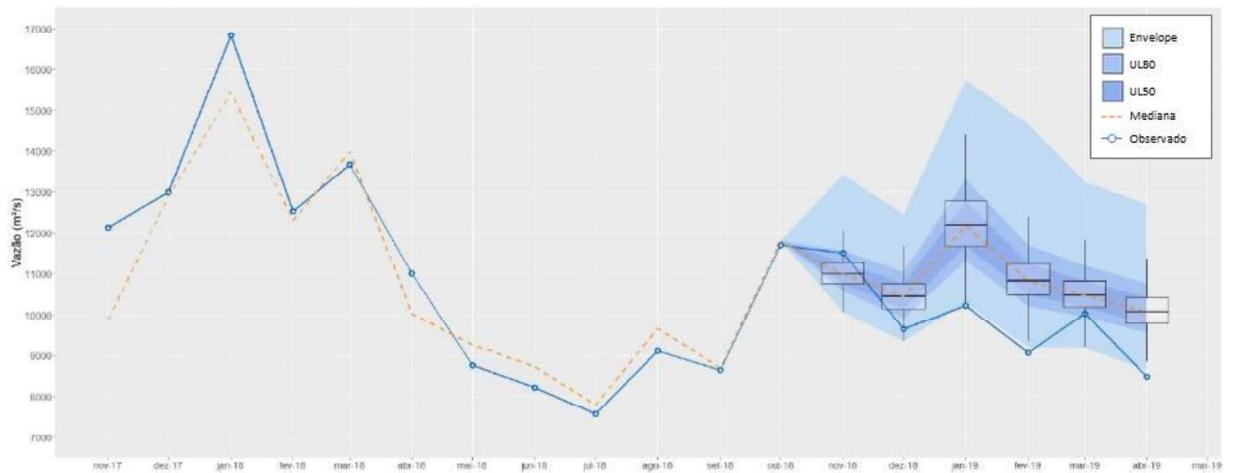


Figura 5.46 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em novembro/2018.

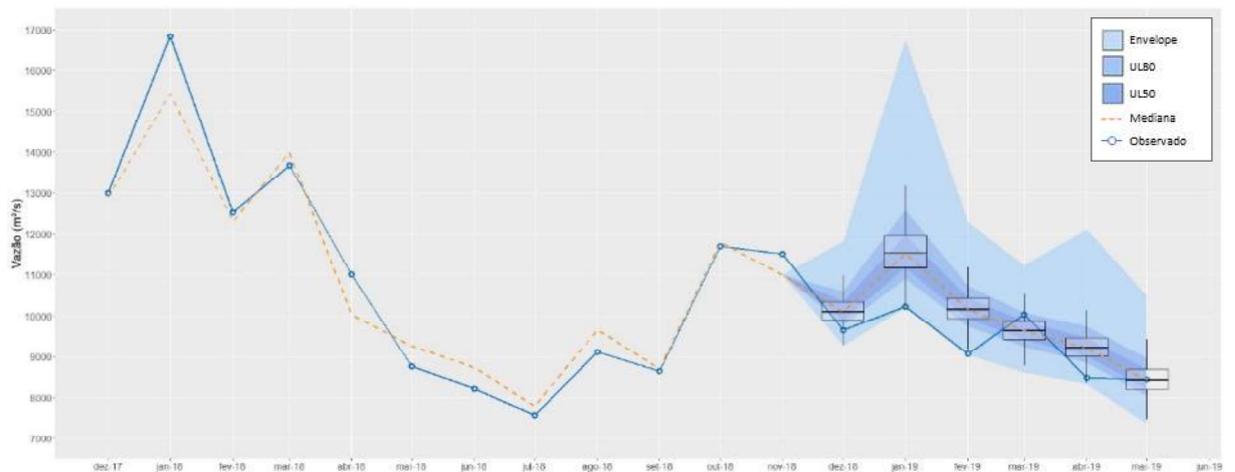


Figura 5.47 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em dezembro/2018.

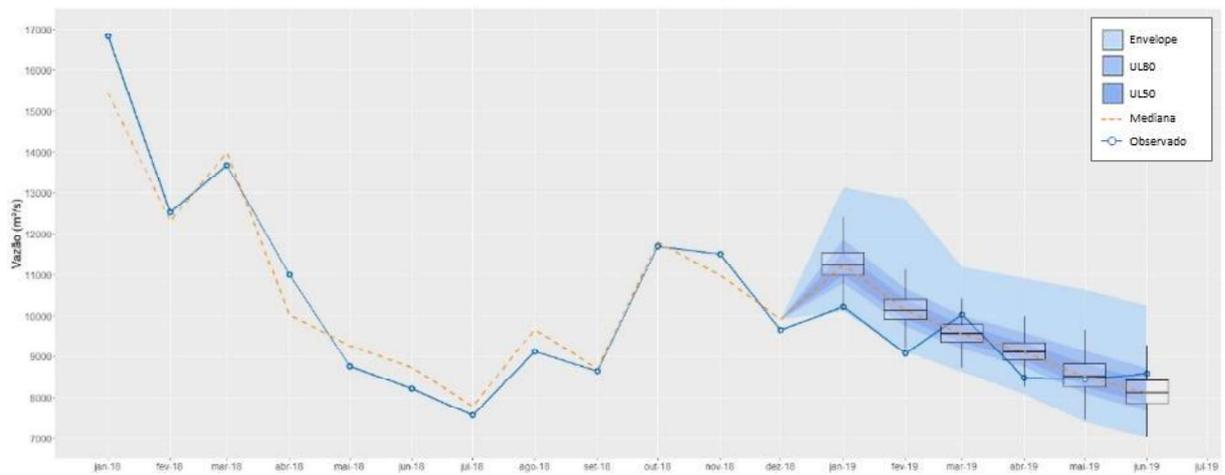


Figura 5.48 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em janeiro/2019.

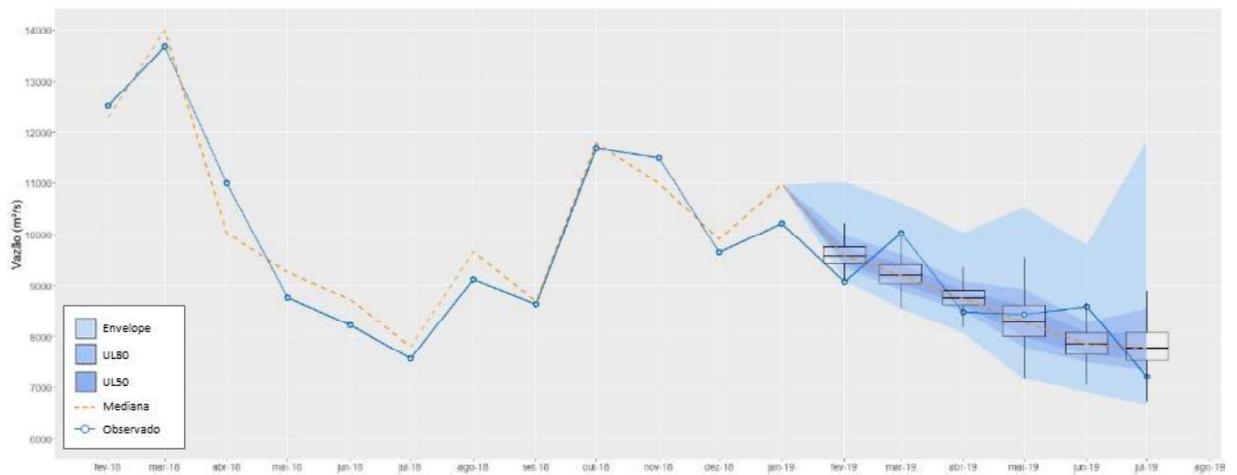


Figura 5.49 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em fevereiro/2019.

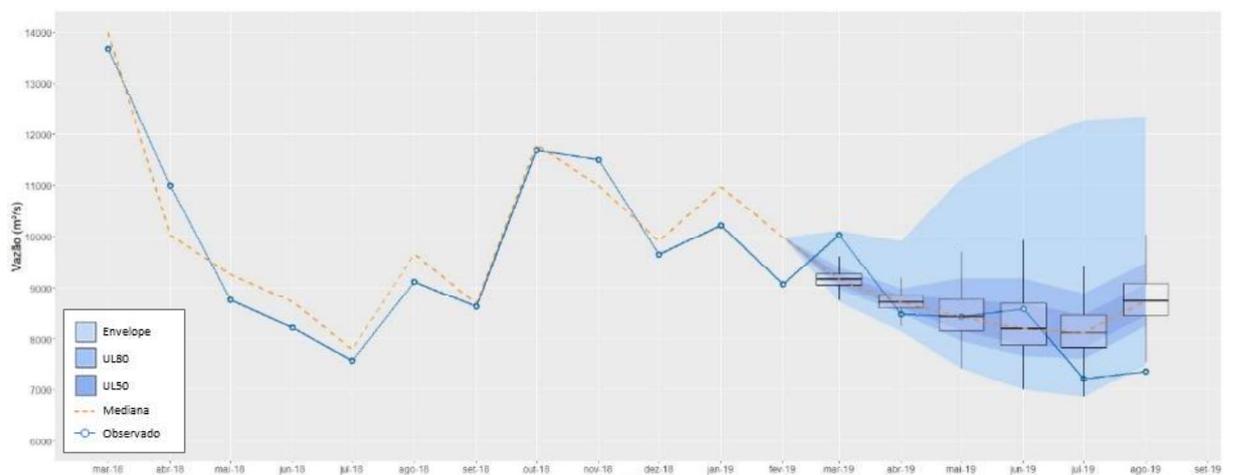


Figura 5.50 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em março/2019.

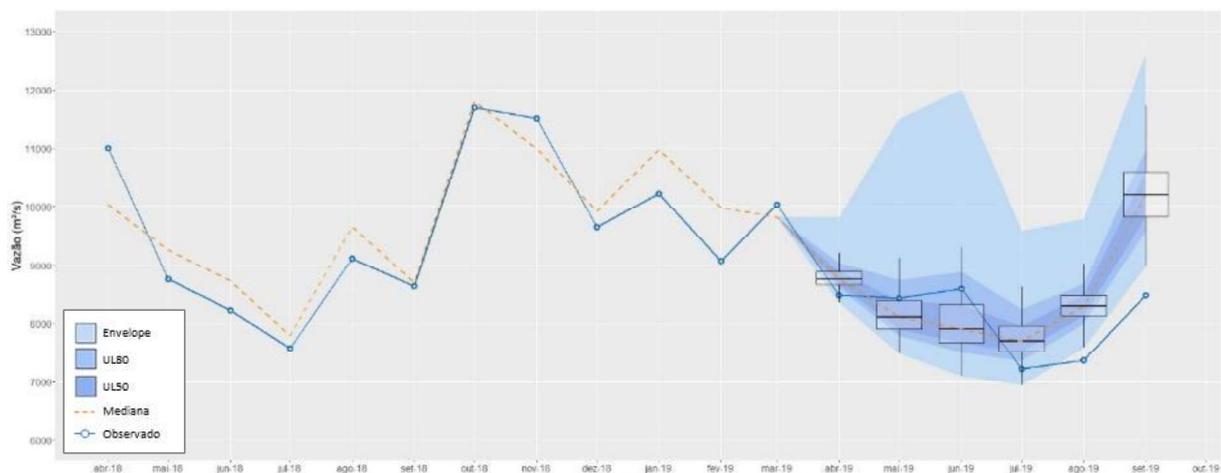


Figura 5.51 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em abril/2019.

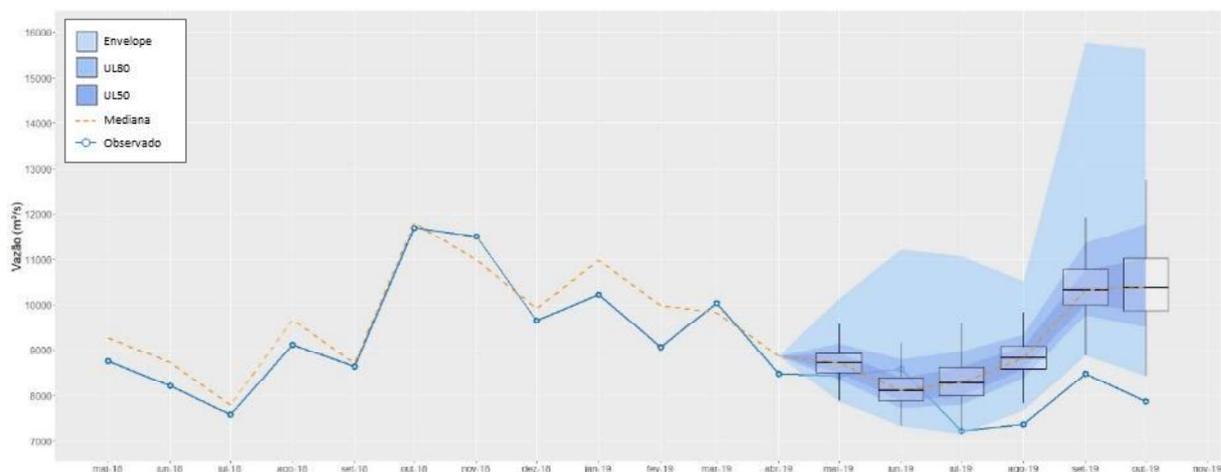


Figura 5.52 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em maio/2019.

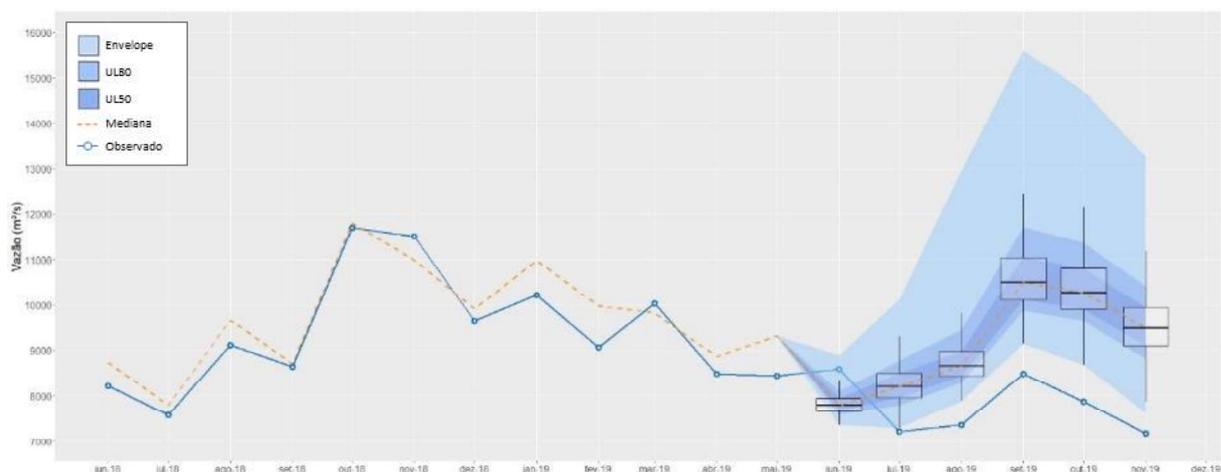


Figura 5.53 - Série de aflúências observadas e simuladas e previsão probabilística das aflúências à UHE Itaipu, para a previsão de precipitação iniciada em junho/2019.

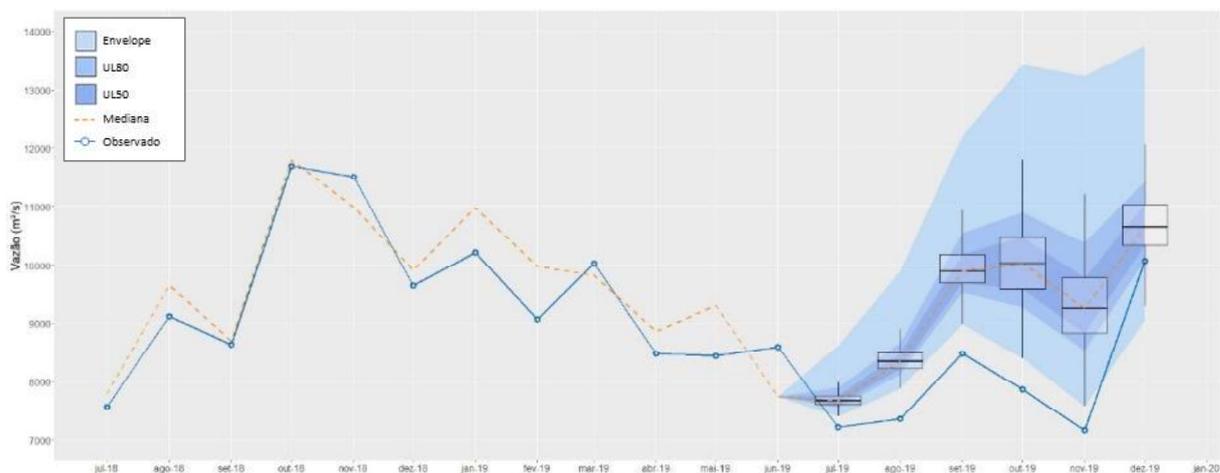


Figura 5.54 - Série de aflúncias observadas e simuladas e previsão probabilística das aflúncias à UHE Itaipu, para a previsão de precipitação iniciada em julho/2019.

A partir de uma avaliação qualitativa percebe-se que, de modo geral, os valores observados de aflúncia foram englobados pelos limites previstos, principalmente nos primeiros meses da previsão. No entanto, em algumas séries de previsão avaliadas, observam-se diferenças significativas entre os valores observados e previstos em alguns meses. Essa diferença possivelmente se deve à limitação da metodologia e do modelo hidrológico na representação dessas grandezas, combinado aos possíveis vieses da previsão de precipitação utilizada.

De forma a se quantificarem essas diferenças (erros da previsão), foram gerados, a partir da mediana das previsões probabilísticas de aflúncia à UHE Itaipu, os gráficos e tabelas apresentados a seguir.

No gráfico da Figura 5.55 são ilustrados os resultados das métricas globais MAE e MRE, calculadas para todo o horizonte da previsão (6 meses), cujos valores encontram-se discriminados na Tabela 5.4. Essas mesmas métricas foram avaliadas por horizonte do mês previsto, ou seja, o desempenho da previsão de início em determinado mês para esse mesmo mês, deste mês para o segundo mês da previsão, e assim por diante. Os resultados são apresentados na Figura 5.56 e na Tabela 5.5.

Além disso, dado que o desempenho das previsões climáticas depende fortemente da estação (TROCCOLI et al., 2008), as previsões hidrológicas delas resultantes também foram avaliadas separadamente para os diferentes meses de início da previsão. Para tanto, gerou-se o gráfico da Figura 5.57, cujos valores podem ser visualizados na Tabela 5.6 (MAE) e na Tabela 5.7 (MRE).

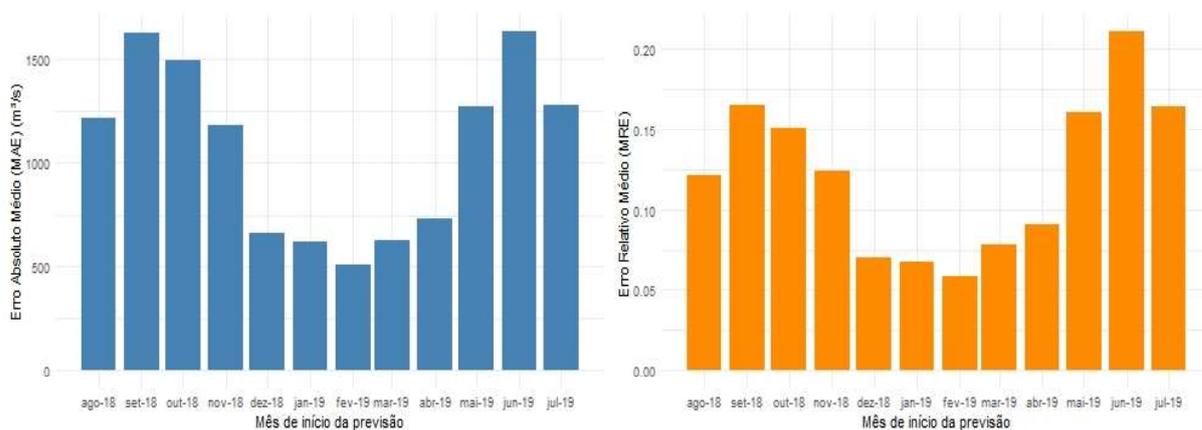


Figura 5.55 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas de afluência à Itaipu para todo o horizonte previsto, para cada mês de início da previsão.

Tabela 5.4 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da de afluência à Itaipu para todo o horizonte previsto, para cada mês de início da previsão.

Início da previsão	MAE (m³/s)	MRE
ago-18	1216	0,122
set-18	1627	0,165
out-18	1491	0,151
nov-18	1182	0,125
dez-18	663	0,070
jan-19	624	0,067
fev-19	506	0,058
mar-19	630	0,079
abr-19	735	0,091
mai-19	1271	0,161
jun-19	1632	0,211
jul-19	1280	0,164

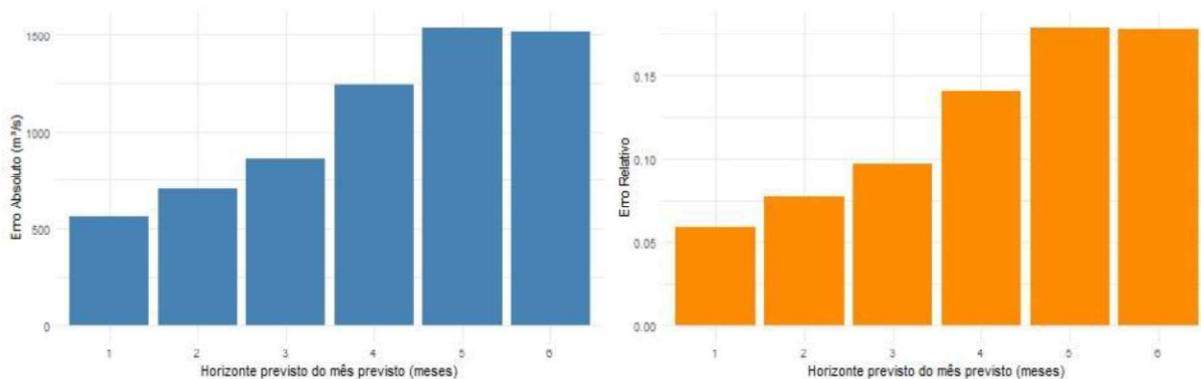


Figura 5.56 - Desempenho geral da mediana das previsões probabilísticas de afluência à Itaipu, para cada horizonte do mês previsto.

Tabela 5.5 - Desempenho geral da mediana das previsões probabilísticas de afluência à Itaipu, para cada horizonte do mês previsto.

Mês Previsto	MAE (m ³ /s)	MRE
1 ^o *	562	0,059
2 ^o	703	0,078
3 ^o	858	0,097
4 ^o	1247	0,141
5 ^o	1539	0,179
6 ^o	1518	0,178

* O 1^o mês previsto é o próprio mês de início da previsão.

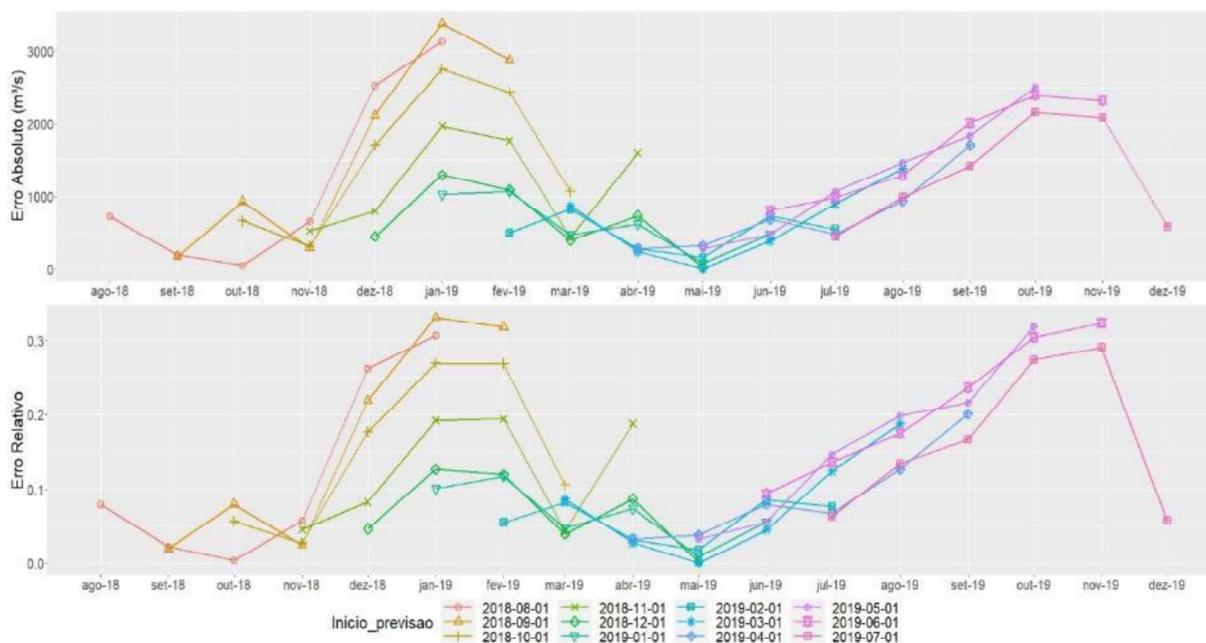


Figura 5.57 - Evolução do desempenho da mediana de cada série de previsão probabilística de afluência à Itaipu, mês a mês.

Tabela 5.6 - Evolução do erro absoluto médio (MAE) da mediana de cada série de previsão probabilística de afluência à Itaipu, mês a mês.

Mês previsto	MAE (m ³ /s) para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	725	171	664	528	449	1026	499	867	280	278	806	453
2 ^o	199	929	320	796	1296	1066	823	239	321	481	982	986
3 ^o	50	285	1708	1967	1084	475	275	5	683	1062	1288	1416
4 ^o	661	2117	2753	1765	395	621	154	387	483	1462	2007	2157
5 ^o	2526	3378	2437	437	733	77	736	896	934	1838	2393	2084
6 ^o	3132	2880	1062	1596	19	480	551	1383	1708	2502	2317	583

* O 1^o mês previsto é o próprio mês de início da previsão.

Tabela 5.7 - Evolução do erro relativo médio (MRE) da mediana de cada série de previsão probabilística de afluência à Itaipu, mês a mês.

Mês previsto	MRE para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	0,08	0,02	0,06	0,05	0,05	0,10	0,06	0,09	0,03	0,03	0,09	0,06
2 ^o	0,02	0,08	0,03	0,08	0,13	0,12	0,08	0,03	0,04	0,06	0,14	0,13
3 ^o	0,00	0,02	0,18	0,19	0,12	0,05	0,03	0,00	0,08	0,15	0,17	0,17
4 ^o	0,06	0,22	0,27	0,19	0,04	0,07	0,02	0,05	0,07	0,20	0,24	0,27
5 ^o	0,26	0,33	0,27	0,04	0,09	0,01	0,09	0,12	0,13	0,22	0,30	0,29
6 ^o	0,31	0,32	0,11	0,19	0,00	0,06	0,08	0,19	0,20	0,32	0,32	0,06

* O 1^o mês previsto é o próprio mês de início da previsão.

Em linhas gerais, desses gráficos e tabelas podem-se tirar as seguintes conclusões:

- Em termos globais, os erros relativos médios (MRE) das medianas das séries de previsão variaram entre 5,8% e 21,1%. Além disso, observa-se que as previsões iniciadas nos meses climatologicamente mais chuvosos (vide Figura 4.2) tendem a apresentar melhores desempenhos (menores erros absolutos e relativos) do que as iniciadas nos meses mais secos;
- Conforme esperado, em média, os erros das previsões crescem à medida em que se aumenta o horizonte de previsão;

- Todas as séries de previsão hidrológica iniciaram-se com erros relativamente baixos, inferiores a 10%, os quais tenderam a aumentar ao longo do horizonte de previsão. Algumas exceções são as previsões iniciadas em dezembro/2018, janeiro/2019, fevereiro/2019 e março/2019, nas quais os erros sofreram redução nos primeiros meses de previsão.

Ressalta-se que a baixa ordem de grandeza dos erros relativos das medianas das previsões indicada nos gráficos anteriores se deve ao fato de que, na determinação das previsões de afluência à Itaipu, foram utilizados valores observados das defluências das usinas a montante. Essa vazão regularizada normalmente corresponde à maior parcela da afluência de Itaipu e, portanto, pode distorcer os resultados obtidos.

Para a verificação probabilística das previsões de afluência por conjunto, o desempenho em termos de erro médio e destreza do *ensemble* em relação à mediana das previsões (previsão determinística de referência) foram avaliados a partir das métricas *Brier Score* (Figura 5.58) e *Brier Skill Score* (Figura 5.59). Para tanto, foram definidos três limiares de vazão, correspondentes a 70%, 60% e 50% de permanência da série histórica utilizada na calibração (jan/2004 a jul/2019), equivalentes a 9.860 m³/s, 10.290 m³/s e 10.752 m³/s, respectivamente.

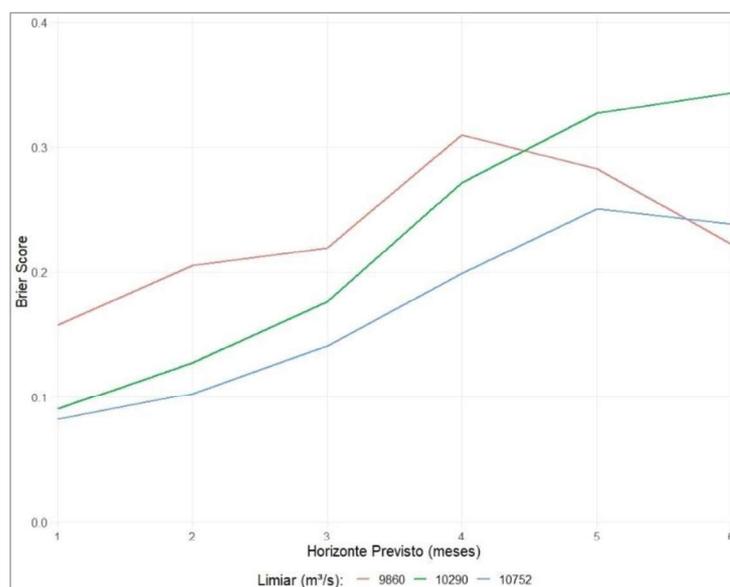


Figura 5.58 - Evolução do BS das previsões probabilísticas de afluência à Itaipu, para cada horizonte do mês previsto.

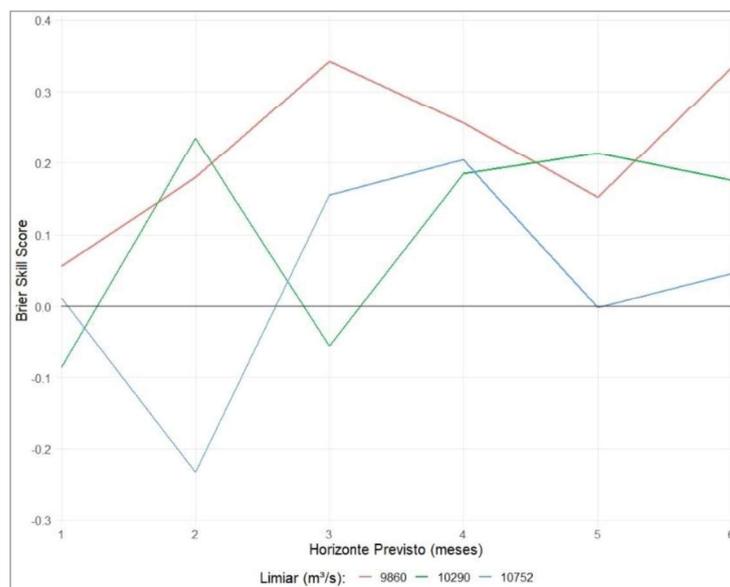
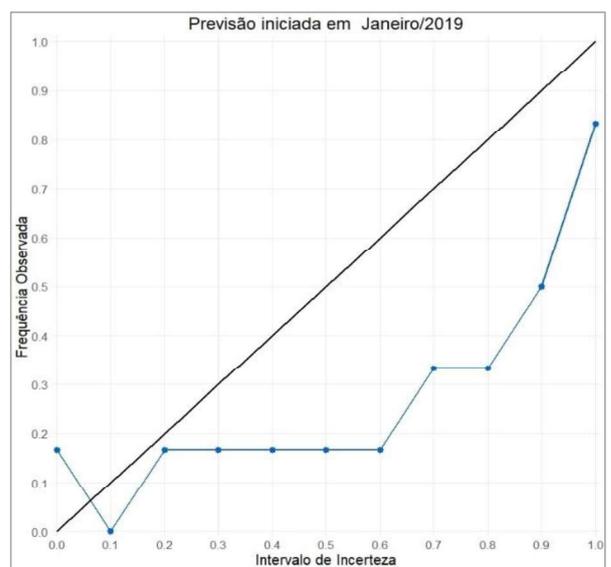
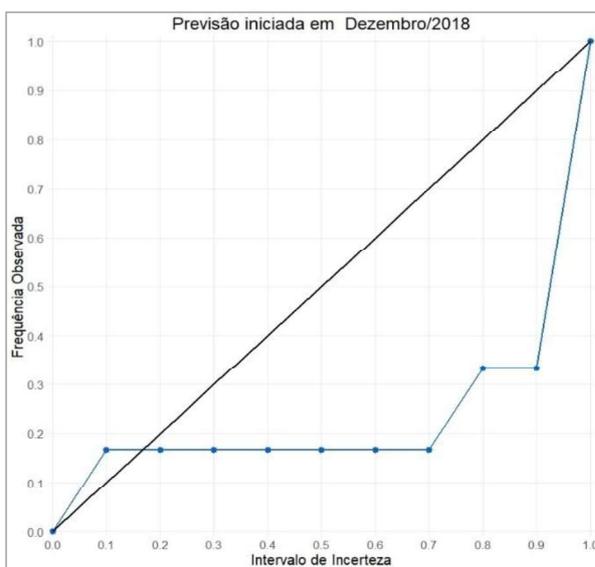
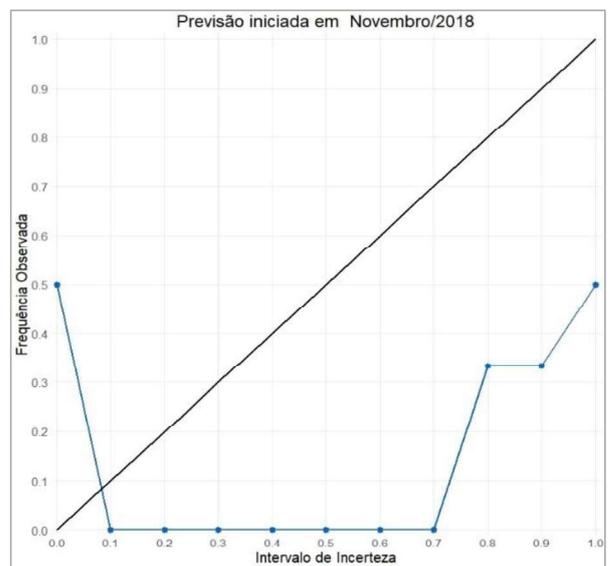
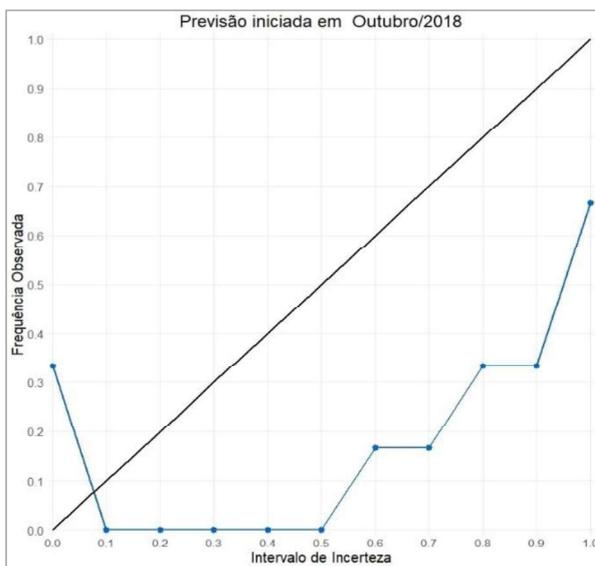
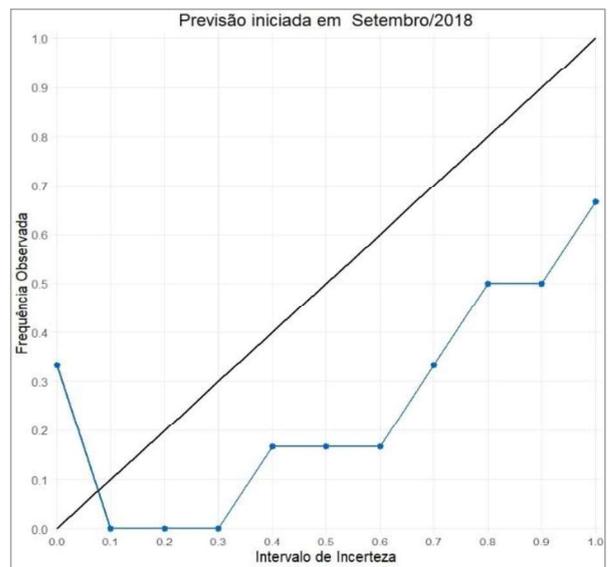
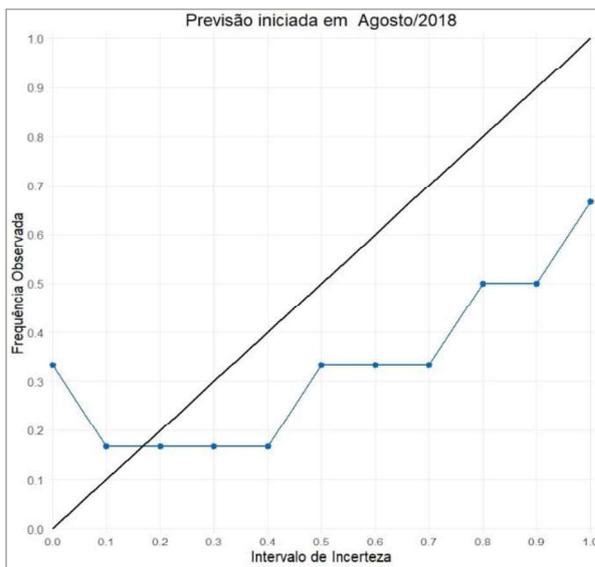


Figura 5.59 - Evolução do BSS das previsões probabilísticas de afluência à Itaipu em relação à mediana das previsões, para cada horizonte do mês previsto.

Observa-se na Figura 5.58 que os valores de BS tendem a aumentar à medida que se amplia o horizonte previsto, indicando um aumento dos erros médios dessas previsões para maiores antecedências, o que condiz com o que foi observado para a mediana das previsões (Figura 5.56). A exceção é o limiar inferior ($9.860 \text{ m}^3/\text{s}$), para o qual há uma redução do erro nos dois últimos meses do horizonte previsto. Ademais, percebe-se que, quanto maior o limiar de vazão, melhor é o desempenho das previsões em estimar a excedência deste nos primeiros quatro meses do horizonte.

A partir da Figura 5.59 é possível observar que, na maior parte do tempo, as previsões probabilísticas apresentaram desempenho superior à previsão de referência (mediana), para os três limiares definidos. Algumas exceções são observadas nos três primeiros meses previstos, para os limiares de $10.290 \text{ m}^3/\text{s}$ e $10.752 \text{ m}^3/\text{s}$.

Por fim, a confiabilidade dos limites de incerteza calculados a partir do *ensemble* de previsões de afluência foi avaliada para cada série de previsão. Desses conjuntos de previsões foram extraídos, além dos UL's de 50% e 80% apresentados nos gráficos da Figura 5.43 à Figura 5.54, os demais limites variando de 0% a 100%, e a partir destes, foram contabilizados os percentuais das observações neles inseridos. Os diagramas resultantes dessa avaliação encontram-se agrupados na Figura 5.60.



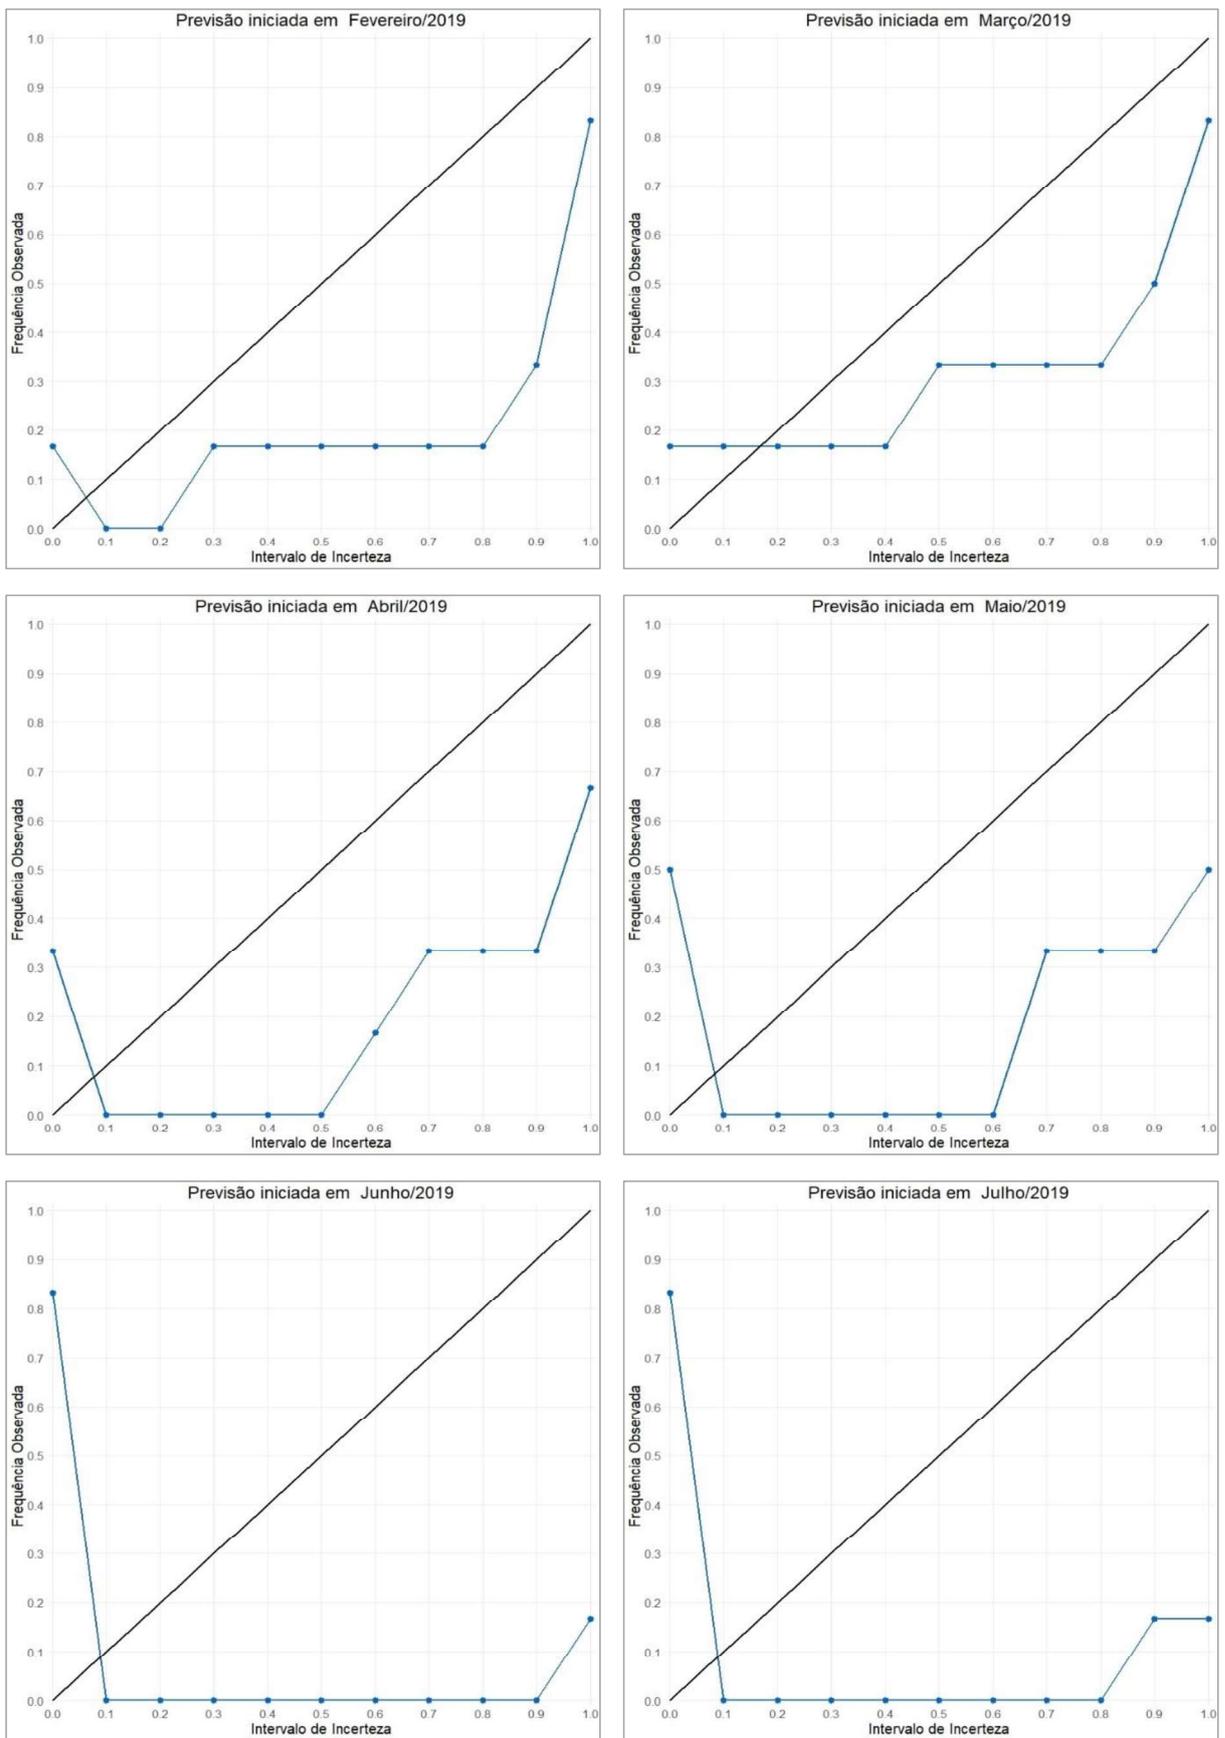


Figura 5.60 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de afluência à Itaipu (linha 1:1 para referência).

Desses diagramas observa-se que, em geral, os limites de incerteza calculados superestimaram a probabilidade de ocorrência das observações ao longo dos seis meses previstos. Além disso, com exceção da previsão iniciada em dezembro/2018, observou-se baixa confiabilidade das envoltórias máximas e mínimas de incerteza, dado que parte dos valores observados estiveram fora desses limites.

5.3.2 Previsão de vazão natural da bacia incremental

Como mencionado anteriormente, o uso de valores observados para as defluências das usinas a montante de Itaipu na determinação das afluições à Itaipu previstas pode distorcer os resultados de desempenho obtidos. Desse modo, a fim de se avaliar a destreza das previsões climáticas na determinação das vazões futuras, deve-se analisar somente a resposta da bacia a essas precipitações, ou seja, as vazões naturais da bacia incremental de Itaipu. Tais vazões foram estimadas a partir da diferença entre as afluições observadas à Itaipu e a soma dessas defluências, ou seja:

$$Q_{INC} = Q_{afIIPU} - (Q_{defPRI} + Q_{defROS}) \quad (5.1)$$

Esse cálculo foi também efetuado a partir das previsões de afluição à Itaipu, obtendo-se, igualmente, as previsões de vazão natural para a bacia incremental, ilustradas nos gráficos da Figura 5.61 à Figura 5.72.

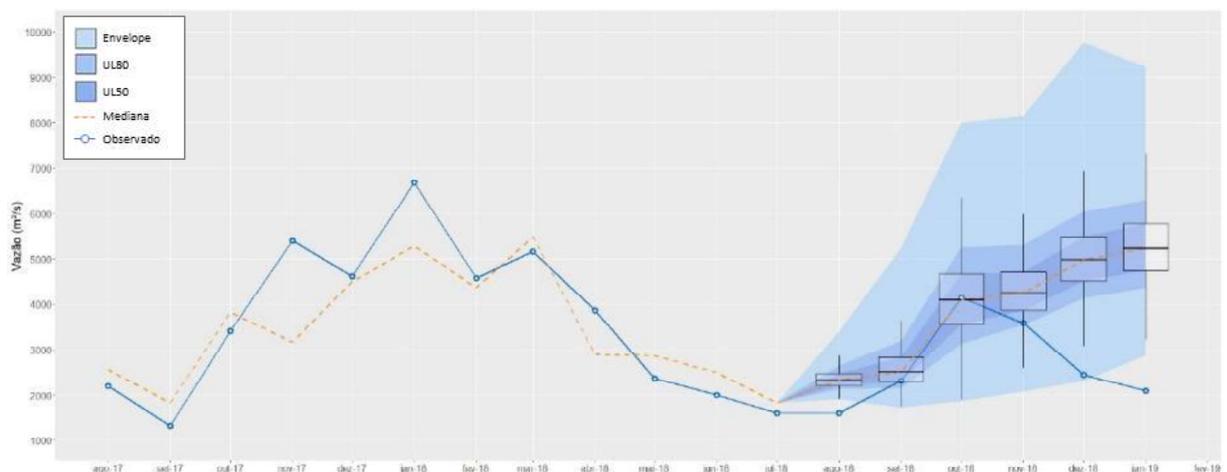


Figura 5.61 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em agosto/2018.

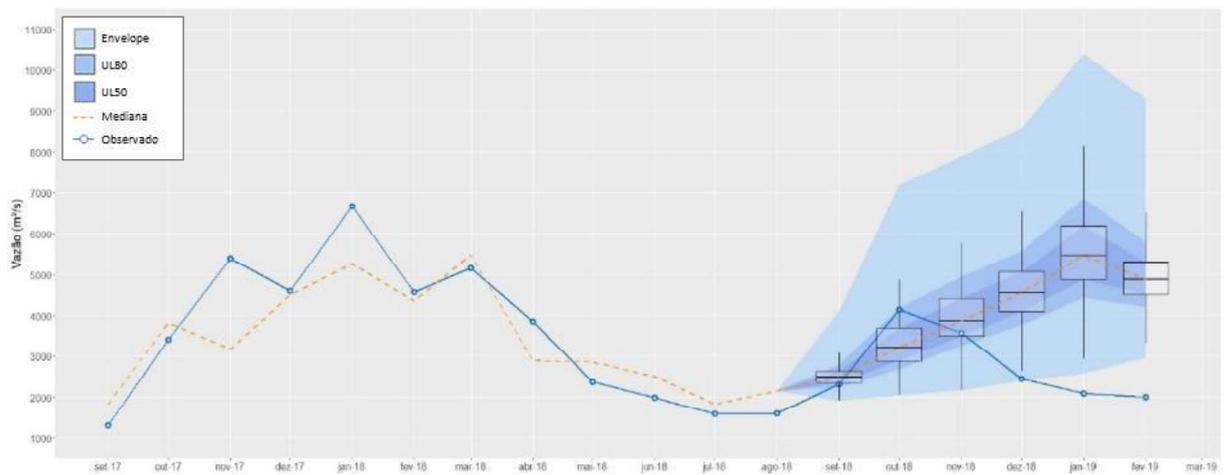


Figura 5.62 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em setembro/2018.

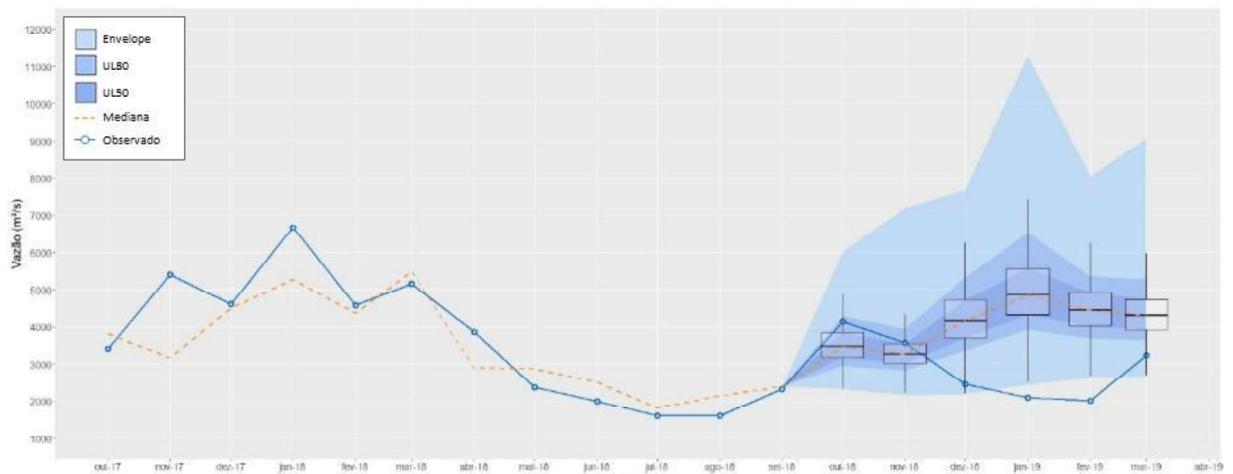


Figura 5.63 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em outubro/2018.

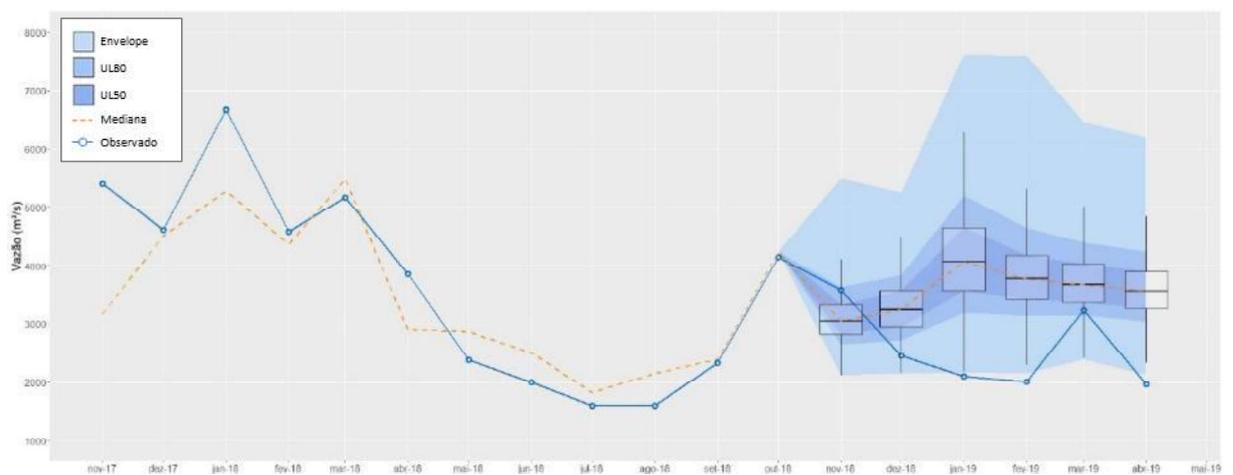


Figura 5.64 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em novembro/2018.

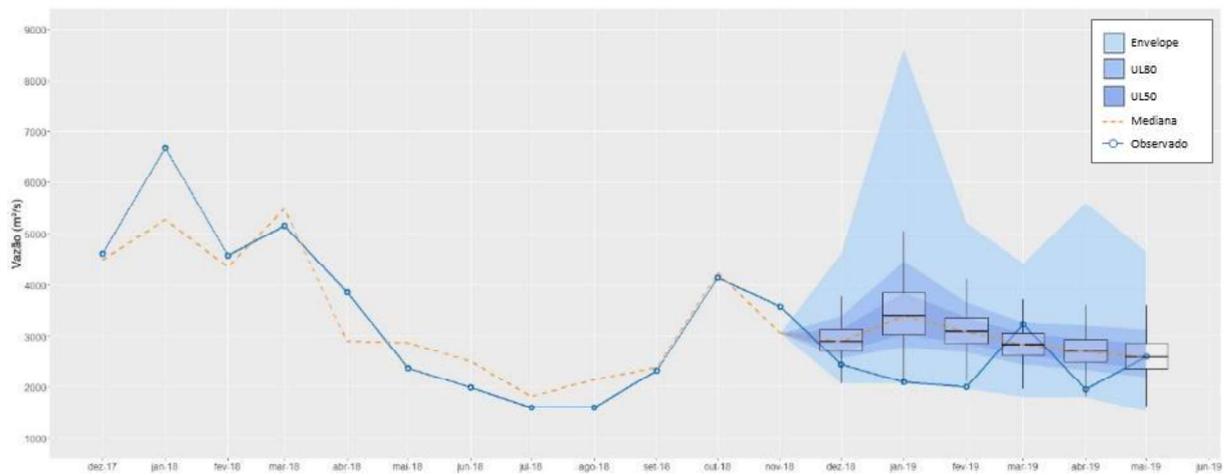


Figura 5.65 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em dezembro/2018.

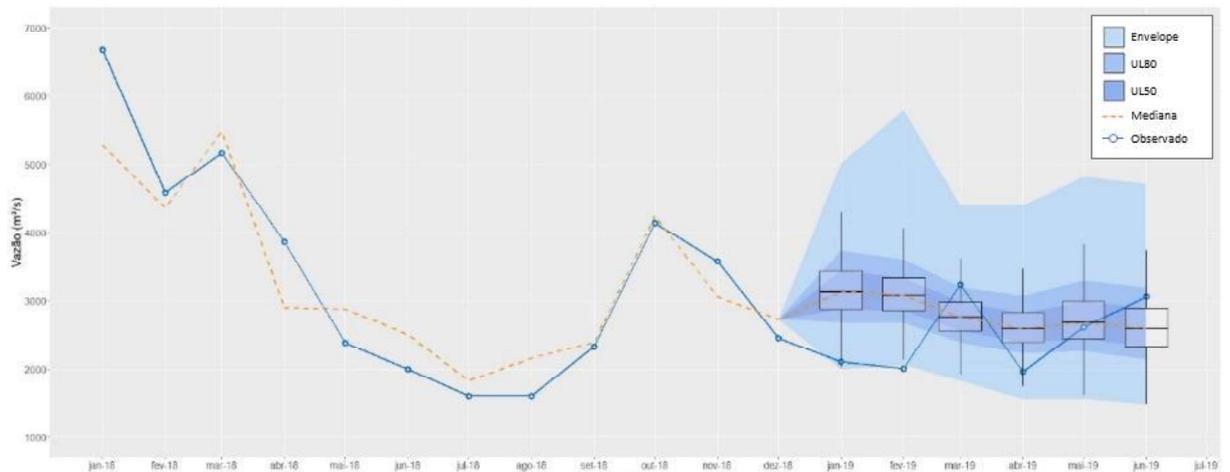


Figura 5.66 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em janeiro/2019.

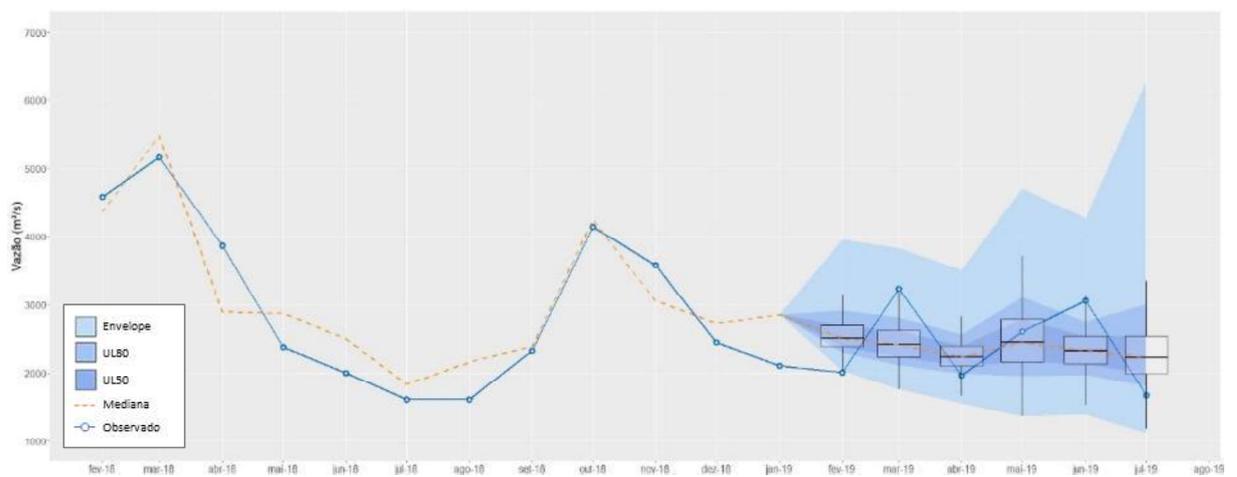


Figura 5.67 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em fevereiro/2019.

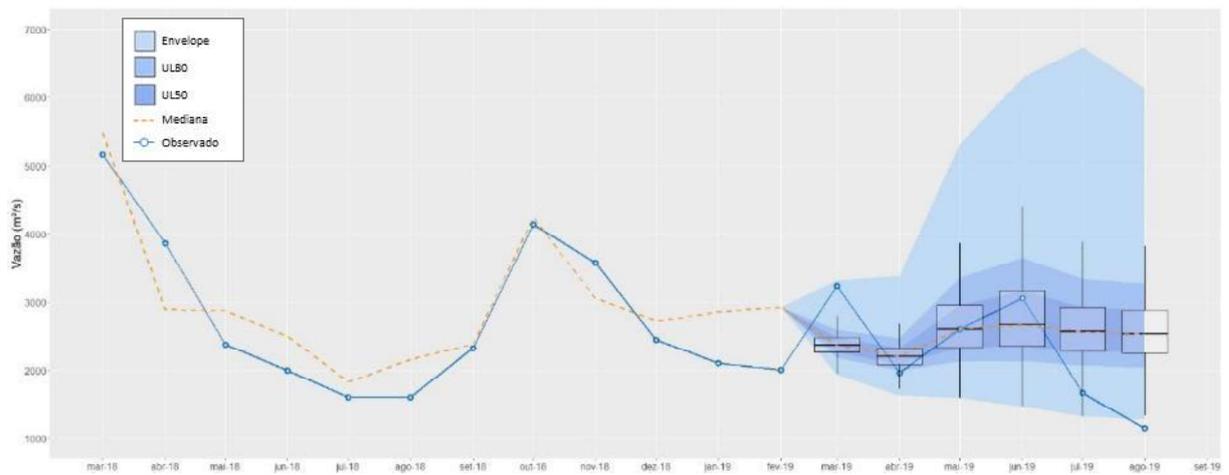


Figura 5.68 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em março/2019.

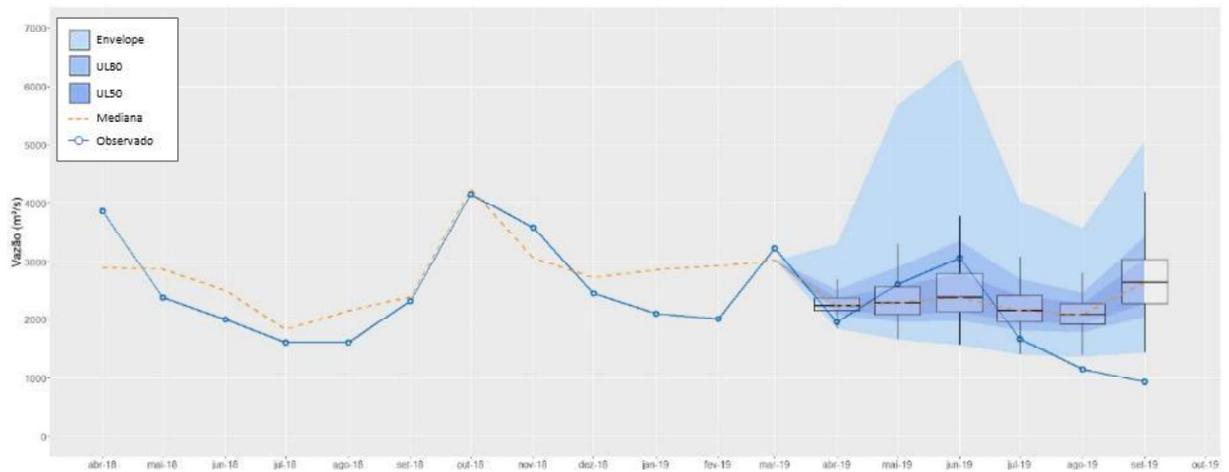


Figura 5.69 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em abril/2019.

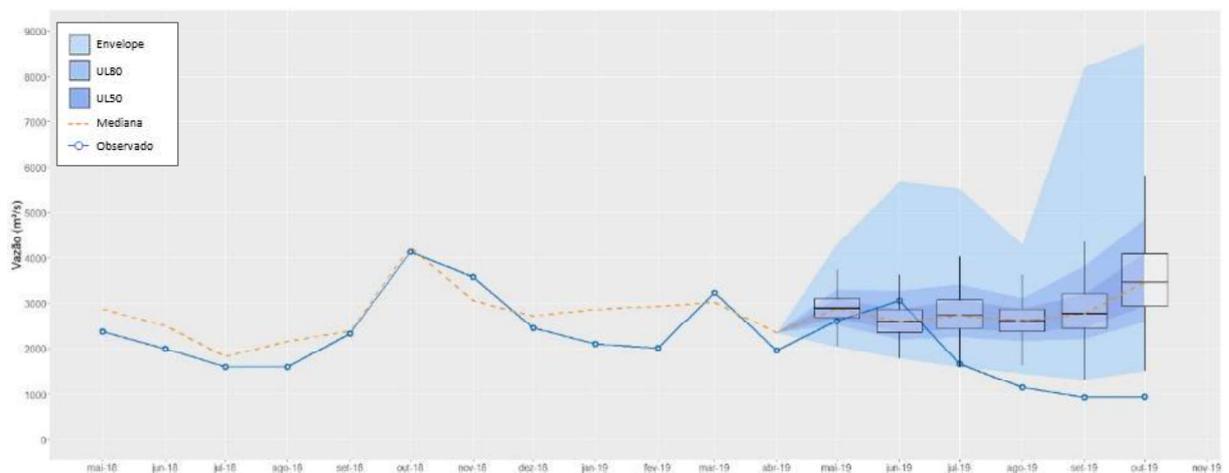


Figura 5.70 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em maio/2019.

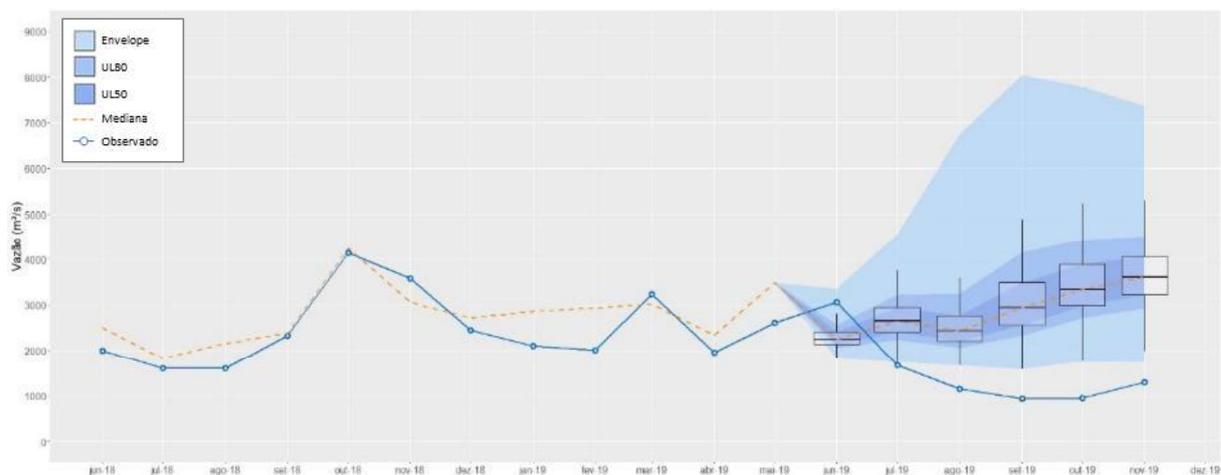


Figura 5.71 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em junho/2019.



Figura 5.72 - Série de vazões observadas e simuladas e previsão probabilística das vazões incrementais à UHE Itaipu, para a previsão de precipitação iniciada em julho/2019.

A partir das medianas dessas previsões, foram então realizadas as mesmas análises anteriormente feitas para as medianas das previsões de afluência à Itaipu, ou seja, das métricas globais MAE e MRE calculadas para todo o horizonte da previsão (Figura 5.73 e Tabela 5.8); dessas mesmas métricas, por horizonte de cada mês previsto (Figura 5.74 e Tabela 5.9); e da evolução de seus erros absolutos e relativos, mês a mês (Figura 5.75, Tabela 5.10 e Tabela 5.11). Esses gráficos também foram gerados para cada sub-bacia modelada individualmente, e são apresentados no APÊNDICE B deste documento.

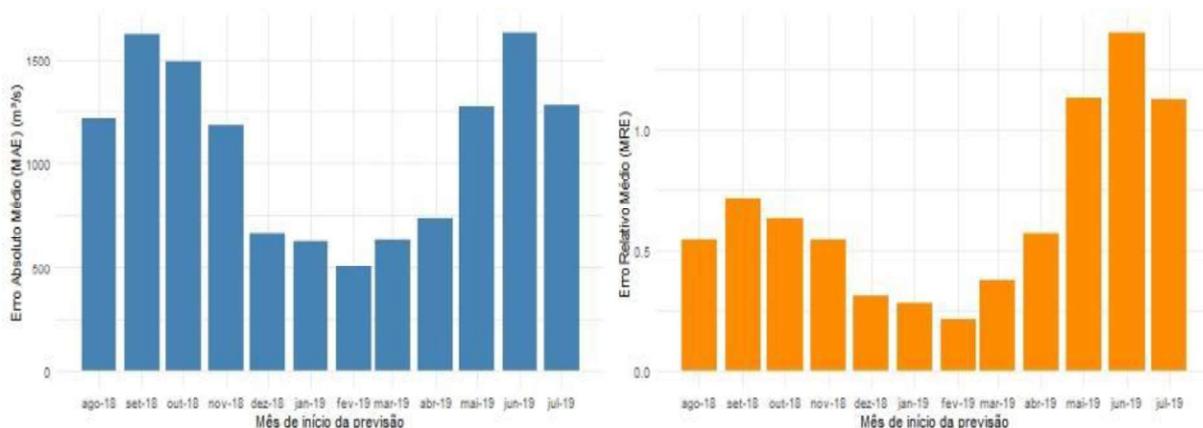


Figura 5.73 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da vazão incremental para todo o horizonte previsto, para cada mês de início da previsão.

Tabela 5.8 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da vazão incremental para todo o horizonte previsto, para cada mês de início da previsão.

Início da previsão	MAE (m³/s)	MRE
ago-18	1216	0,543
set-18	1627	0,714
out-18	1491	0,633
nov-18	1182	0,539
dez-18	663	0,307
jan-19	624	0,278
fev-19	506	0,212
mar-19	630	0,376
abr-19	735	0,570
mai-19	1271	1,128
jun-19	1632	1,405
jul-19	1280	1,122

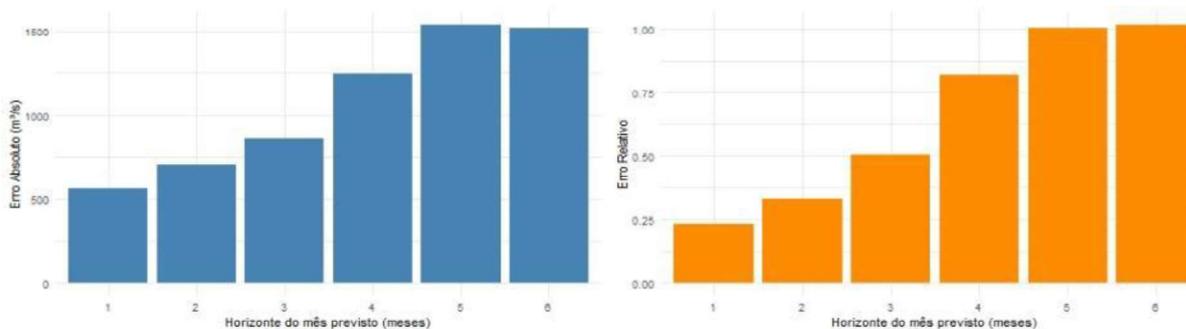


Figura 5.74 - Desempenho geral da mediana das previsões probabilísticas da vazão incremental, para cada horizonte do mês previsto.

Tabela 5.9 - Desempenho geral da mediana das previsões probabilísticas da vazão incremental, para cada horizonte do mês previsto.

Mês Previsto	MAE (m ³ /s)	MRE
1 ^o *	562	0,23
2 ^o	703	0,33
3 ^o	858	0,50
4 ^o	1247	0,82
5 ^o	1539	1,01
6 ^o	1518	1,02

* O 1^o mês previsto é o próprio mês de início da previsão.

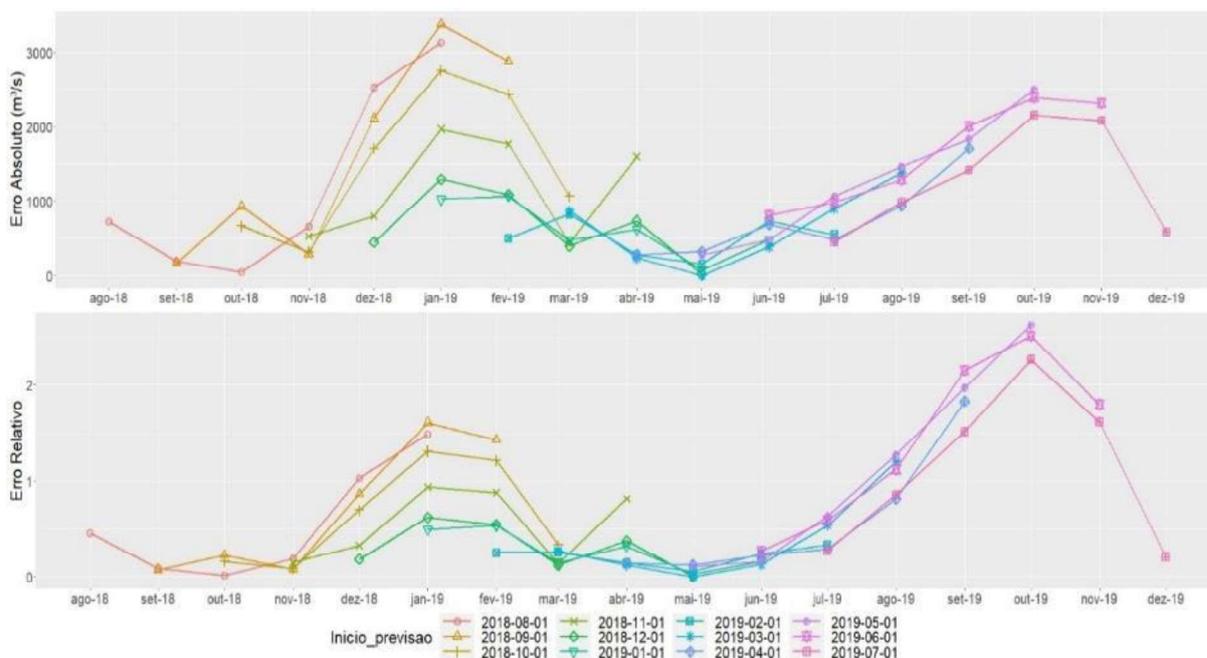


Figura 5.75 - Evolução do desempenho da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.

Tabela 5.10 - Evolução do erro absoluto médio (MAE) da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.

Mês previsto	MAE (m ³ /s) para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	725	171	664	528	449	1026	499	867	280	278	806	453
2 ^o	199	929	320	796	1296	1066	823	239	321	481	982	986
3 ^o	50	285	1708	1967	1084	475	275	5	683	1062	1288	1416
4 ^o	661	2117	2753	1765	395	621	154	387	483	1462	2007	2157
5 ^o	2526	3378	2437	437	733	77	736	896	934	1838	2393	2084
6 ^o	3132	2880	1062	1596	19	480	551	1383	1708	2502	2317	583

* O 1^o mês previsto é o próprio mês de início da previsão.

Tabela 5.11 - Evolução do erro relativo médio (MRE) da mediana de cada série de previsão probabilística da vazão incremental, mês a mês.

Mês previsto	MRE para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	0,45	0,07	0,16	0,15	0,18	0,49	0,25	0,27	0,14	0,11	0,26	0,27
2 ^o	0,09	0,22	0,09	0,32	0,62	0,53	0,25	0,12	0,12	0,16	0,59	0,86
3 ^o	0,01	0,08	0,70	0,94	0,54	0,15	0,14	0,00	0,22	0,64	1,12	1,52
4 ^o	0,18	0,86	1,31	0,88	0,12	0,32	0,06	0,13	0,29	1,27	2,15	2,26
5 ^o	1,03	1,61	1,21	0,14	0,37	0,03	0,24	0,54	0,81	1,97	2,51	1,62
6 ^o	1,49	1,43	0,33	0,81	0,01	0,16	0,33	1,20	1,83	2,63	1,80	0,20

* O 1^o mês previsto é o próprio mês de início da previsão.

Em linhas gerais, desses gráficos e tabelas podem-se tirar as seguintes conclusões:

- Semelhantemente às previsões de afluência à Itaipu, as previsões iniciadas nos meses climatologicamente mais chuvosos apresentaram melhores desempenhos (menores erros absolutos e relativos) do que as iniciadas nos meses mais secos, o que indica que tendem a prever melhor as vazões naqueles meses em que os volumes precipitados são menores. Em termos globais, os erros relativos médios (MRE) das séries previstas variaram entre 21,2% e 140,5%, valores significativamente superiores aos encontrados para as previsões de afluência à Itaipu, confirmando a grande influência das vazão regularizada nesses resultados;

- Igualmente, em média, os erros das previsões crescem à medida que se aumenta o horizonte de previsão;
- Todas as séries de previsão hidrológica iniciaram-se com erros inferiores a 50%, os quais tenderam a aumentar ao longo do horizonte de previsão. Algumas exceções são as previsões iniciadas em dezembro/2018, janeiro/2019, fevereiro/2019 e março/2019, nas quais os erros sofreram redução nos primeiros meses de previsão.

Da mesma forma, avaliou-se o desempenho das previsões probabilísticas de vazão incremental em termos de erro médio, destreza e confiabilidade. Para o cálculo das métricas *Brier Score* (Figura 5.76) e *Brier Skill Score* (Figura 5.77), os três limiares de vazão também foram definidos como 70%, 60% e 50% de permanência da série histórica utilizada na calibração, equivalentes a 1.814 m³/s, 2.153 m³/s e 2.516 m³/s, respectivamente.

Observa-se na Figura 5.76 que, semelhantemente às previsões de afluência à Itaipu, os valores de BS tendem a aumentar à medida que se amplia o horizonte previsto, indicando um aumento dos erros médios dessas previsões para maiores antecedências, o que corrobora o que foi observado para a mediana das previsões (Figura 5.74). Ademais, percebe-se que os melhores resultados são observados para o menor limiar escolhido (1.814 m³/s) para todo o horizonte previsto, e que os resultados para o segundo e terceiro limiar são bastante semelhantes.

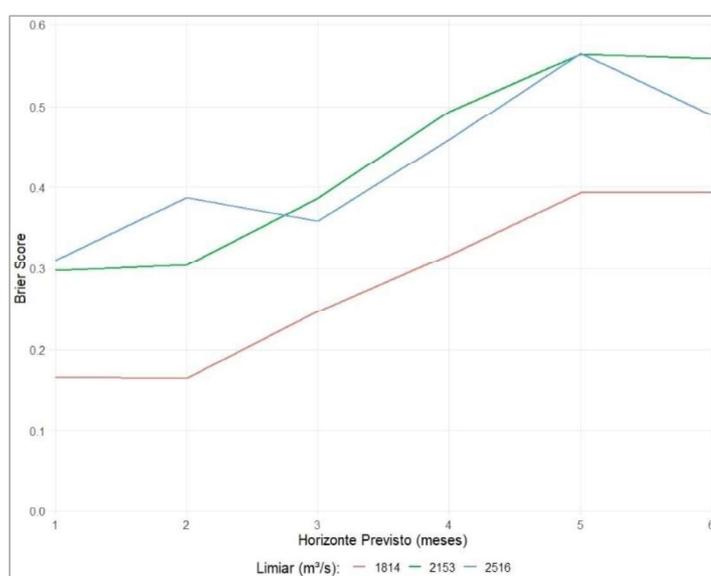


Figura 5.76 - Evolução do BS das previsões probabilísticas de vazão incremental à Itaipu, para cada horizonte do mês previsto.

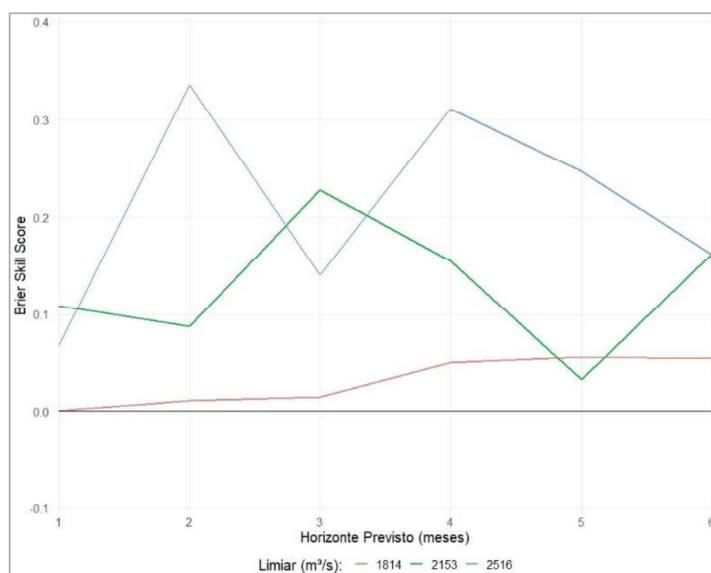
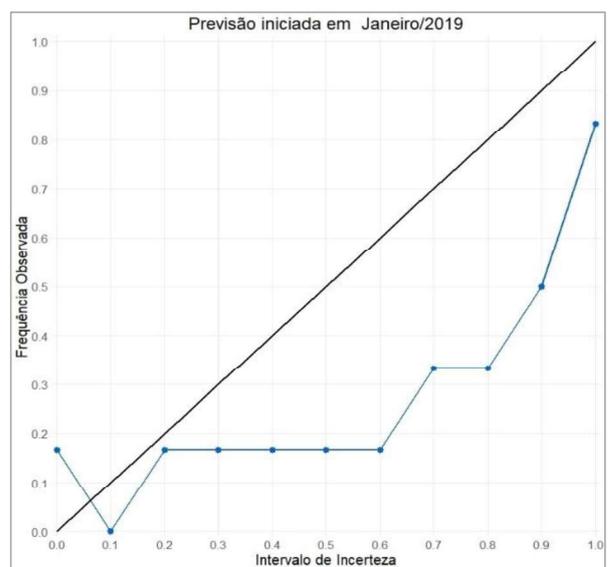
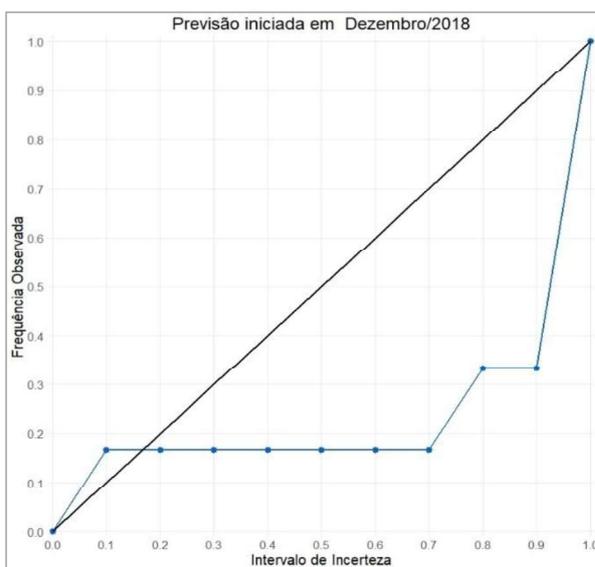
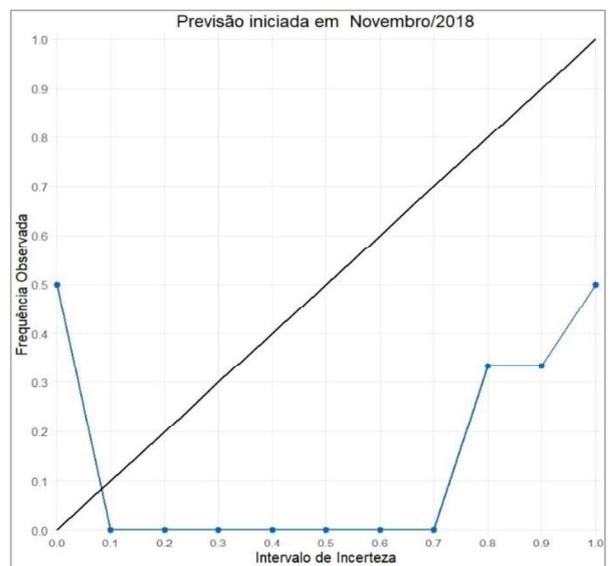
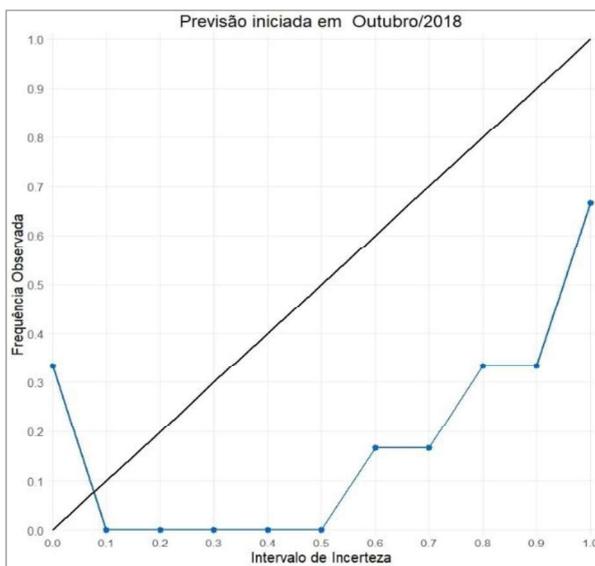
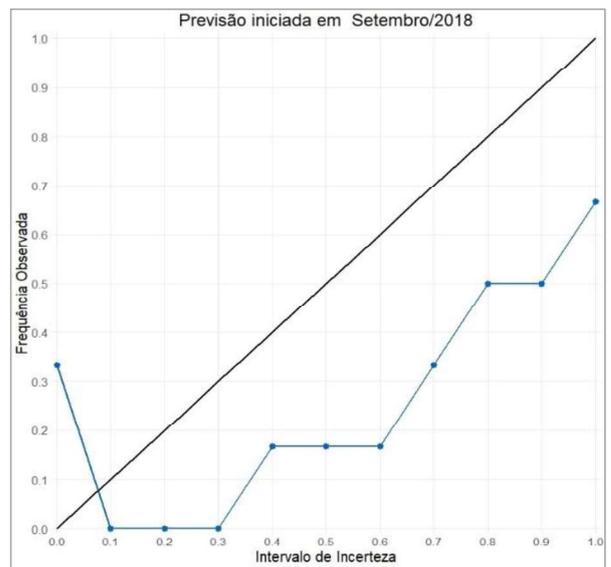
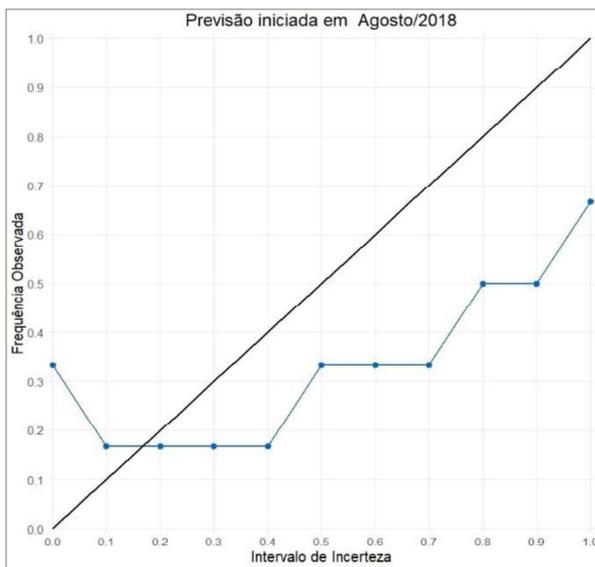


Figura 5.77 - Evolução do BSS das previsões probabilísticas de vazão incremental à Itaipu em relação à mediana das previsões, para cada horizonte do mês previsto.

Já a partir da Figura 5.77 é possível observar que, para todo o horizonte previsto, as previsões probabilísticas apresentaram desempenho superior à previsão de referência, para qualquer um dos limiares definidos. Tal fato evidencia as vantagens de uso das previsões por conjunto em lugar das previsões determinísticas, aqui representadas pela mediana das previsões.

Por fim, a confiabilidade dos limites de incerteza calculados a partir do *ensemble* de previsões de vazão incremental à Itaipu foi avaliada para cada série de previsão. Desses conjuntos de previsões também foram extraídos, além dos UL's de 50% e 80% apresentados nos gráficos da Figura 5.61 à Figura 5.72, os demais limites variando de 0% a 100%, e a partir destes, foram contabilizados os percentuais das observações neles inseridos. Os diagramas resultantes dessa avaliação encontram-se agrupados na Figura 5.78.

Observa-se que tais diagramas são similares aos obtidos para as previsões de afluência à Itaipu (Figura 5.60), uma vez as séries observadas e previstas de vazão incremental são originárias das respectivas séries de afluência à Itaipu, subtraídas de valores constantes (defluências observadas das usinas a montante). Assim, desses diagramas também é possível observar que, em geral, os limites de incerteza calculados superestimaram a probabilidade de ocorrência das observações ao longo dos seis meses previstos. Além disso, com exceção da previsão iniciada em dezembro/2018, observou-se baixa confiabilidade das envoltórias máximas e mínimas de incerteza, especialmente para as previsões iniciadas entre abril/2019 e julho/2019.



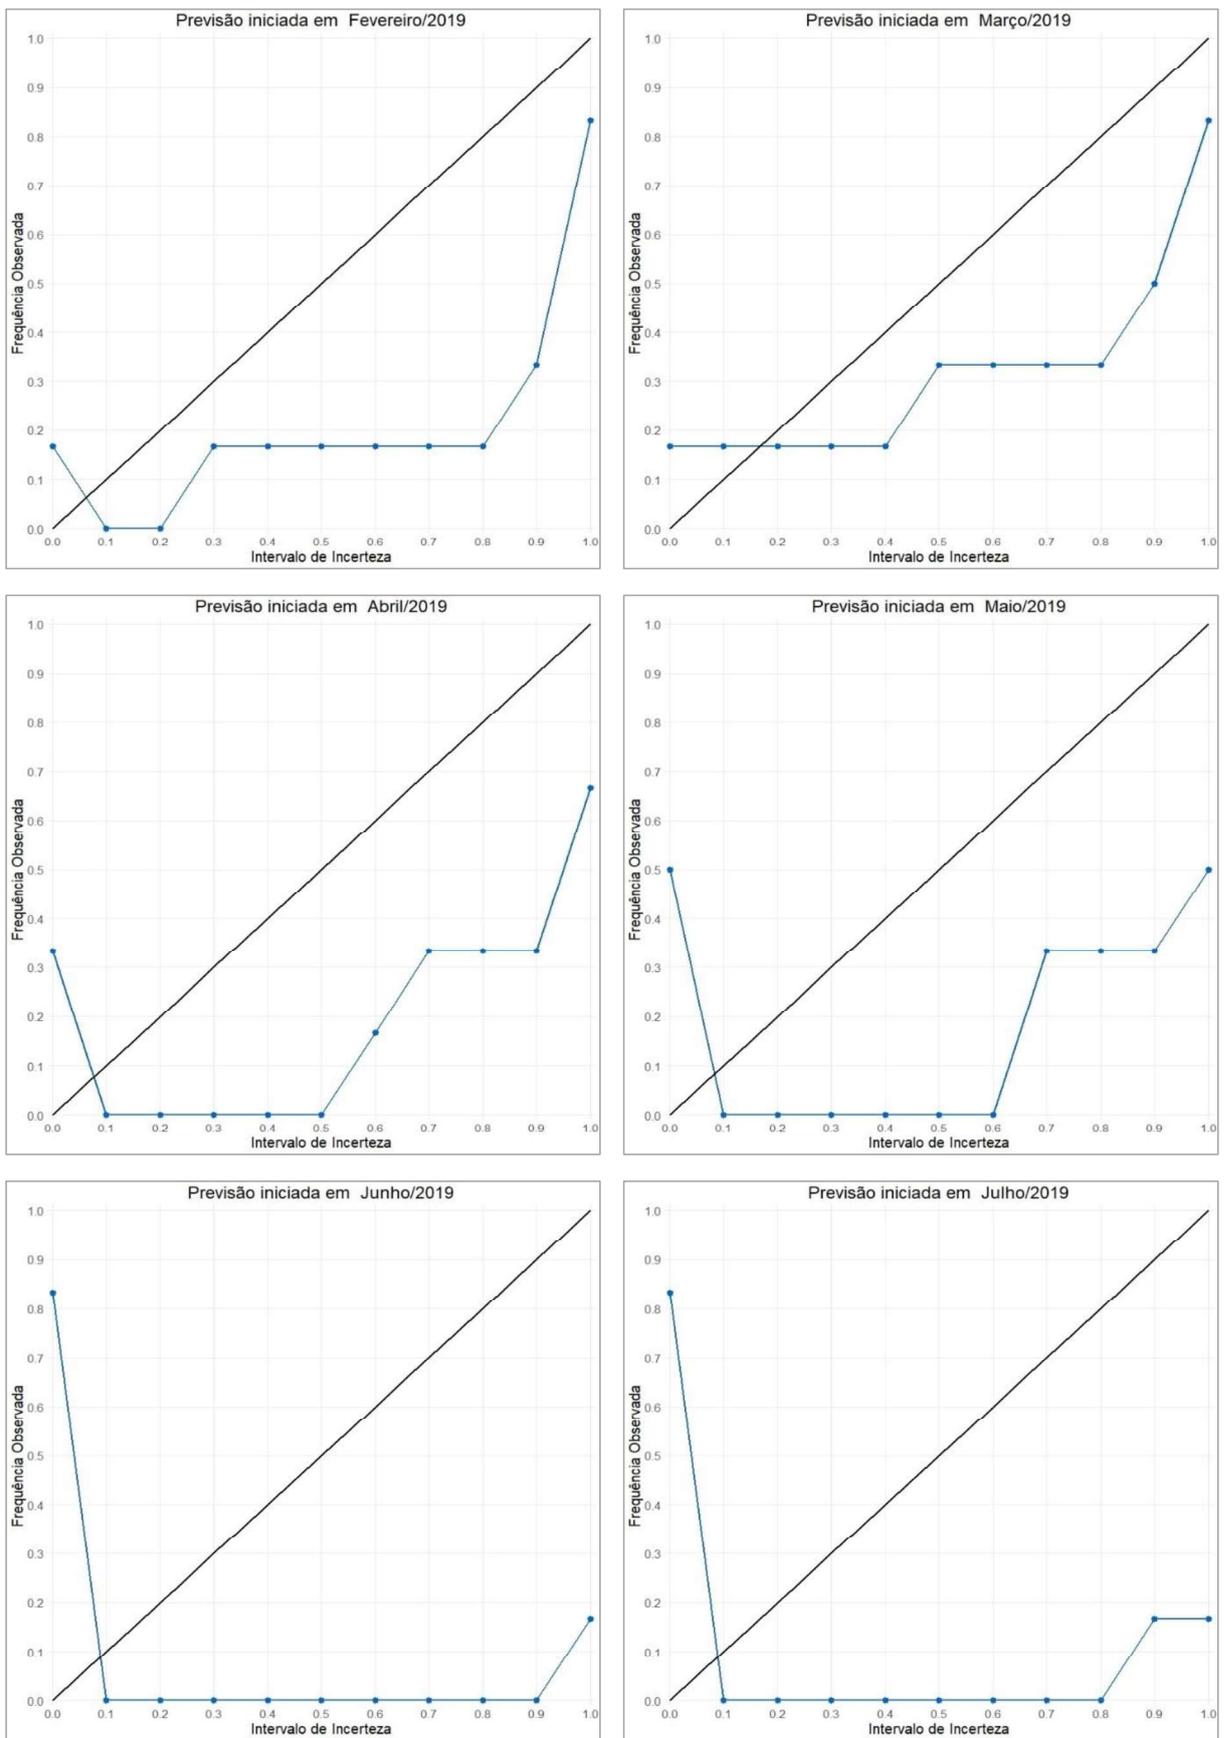
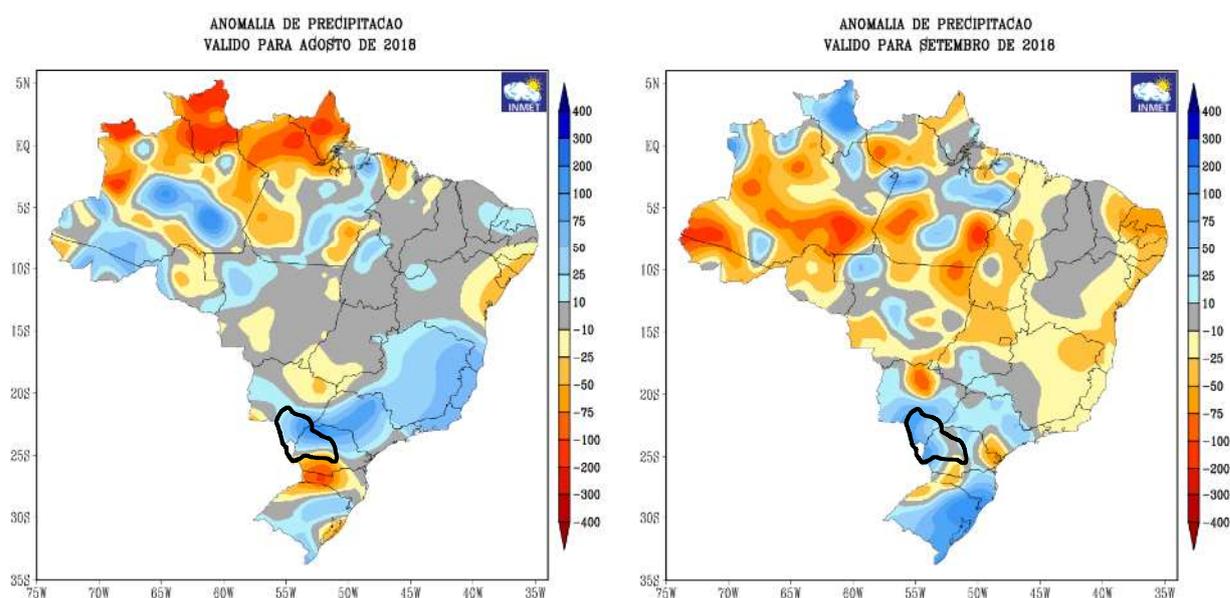


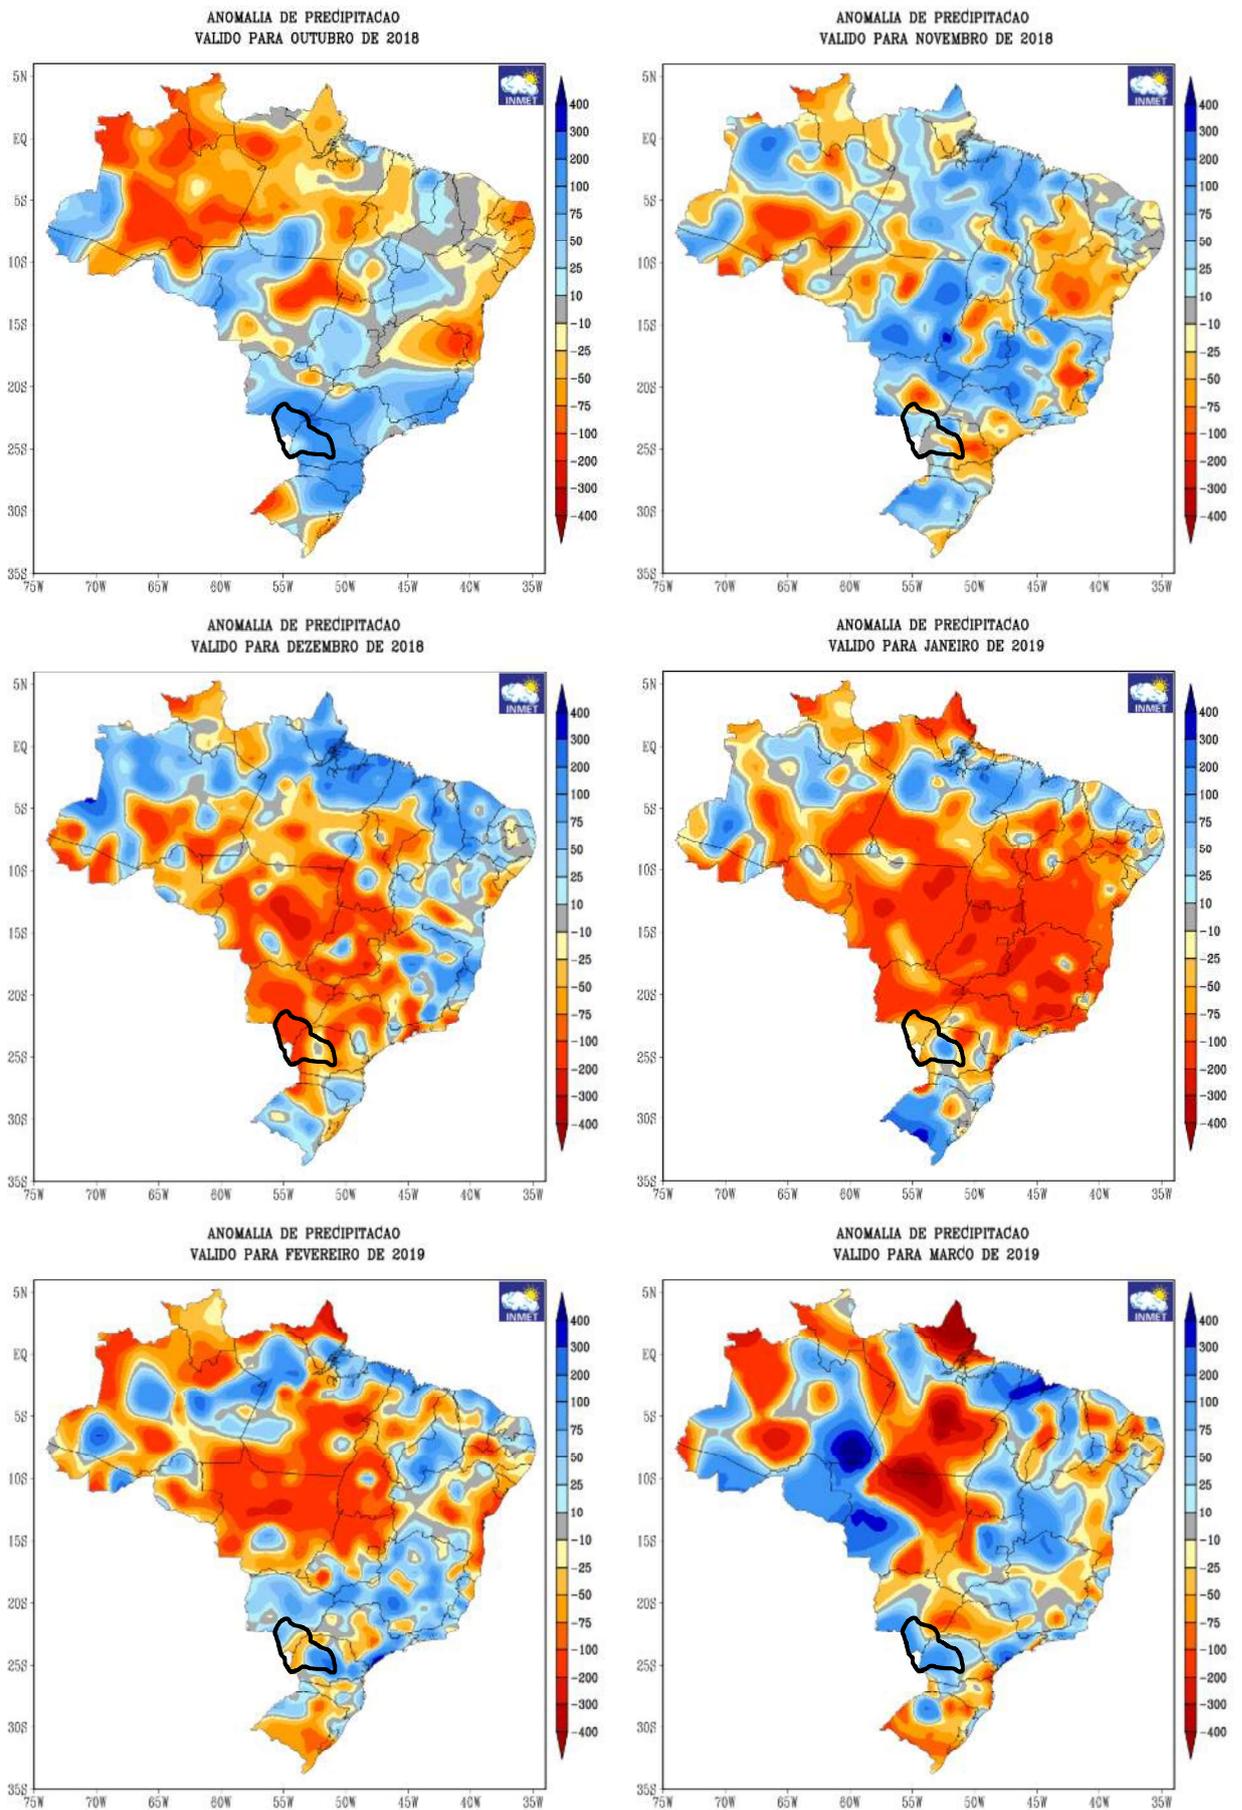
Figura 5.78 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de vazão incremental à Itaipu (linha 1:1 para referência).

Ressalta-se que, uma vez que a amostra de previsões avaliada é bastante reduzida e pouco representativa (de apenas 12 meses de previsão, com atuação do fenômeno climático El Niño), as conclusões aqui apresentadas não podem ser generalizadas para quaisquer anos e padrões climáticos atuantes. Nesse sentido, faz-se necessária a análise do contexto meteorológico em que tais previsões se inserem, para avaliar se há correlação entre esse contexto e o desempenho observado para as previsões hidrológicas.

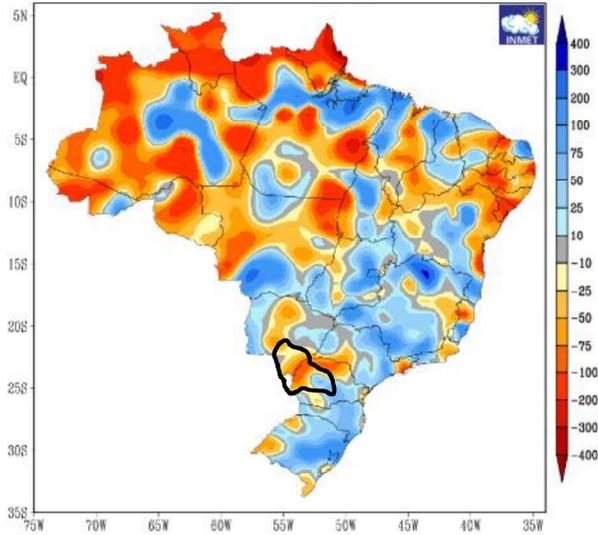
5.3.3 Previsão de precipitação sobre a bacia incremental

A fim de se investigar o contexto meteorológico em que as previsões hidrológicas anteriormente avaliadas se inserem, foram analisados os mapas de anomalia de precipitação mensais dos meses contemplados nessas previsões, os quais encontram-se agrupados na Figura 5.79. As anomalias de precipitação referem-se à diferença entre o volume precipitado e a precipitação média (climatologia) naquele mês, de modo que anomalias negativas indicam chuvas abaixo da média histórica do mês (tons em vermelho), e anomalias positivas, chuvas acima das média histórica do mês (tons em azul).

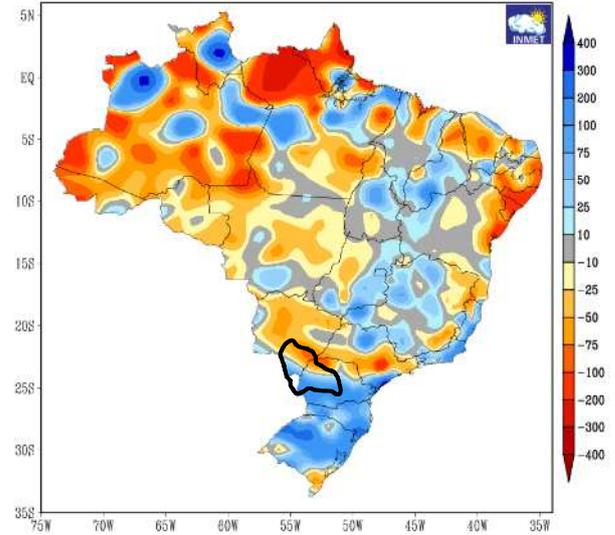




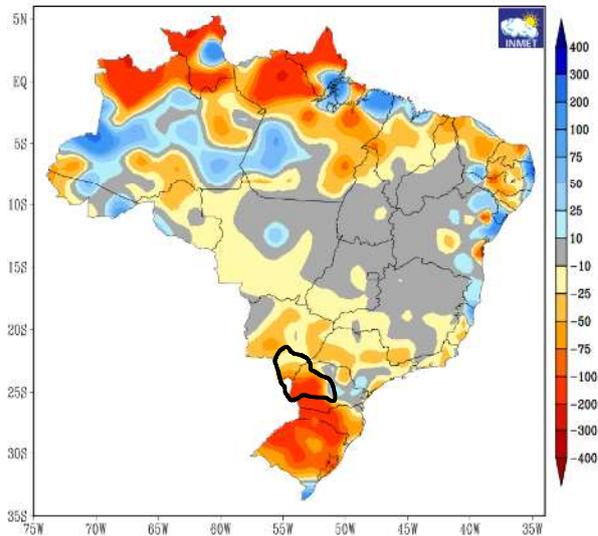
ANOMALIA DE PRECIPITACAO
VALIDO PARA ABRIL DE 2019



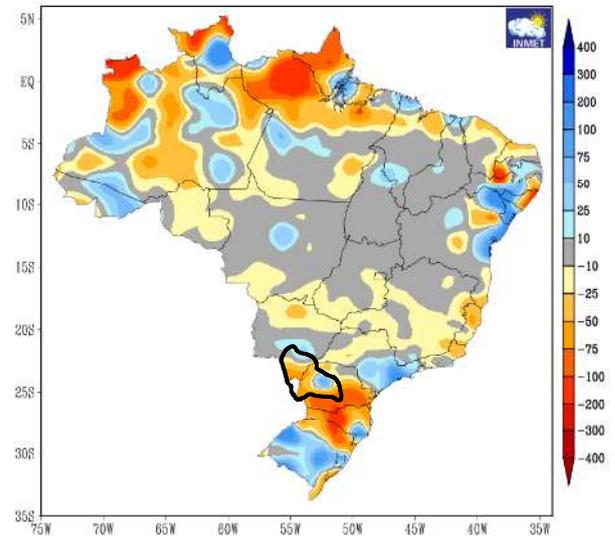
ANOMALIA DE PRECIPITACAO
VALIDO PARA MAIO DE 2019



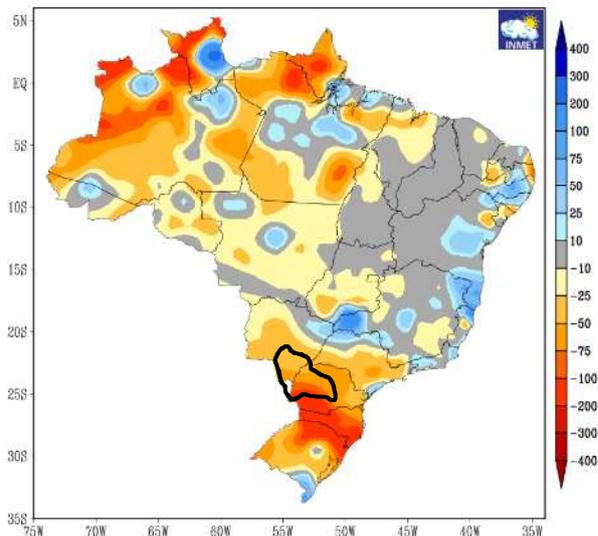
ANOMALIA DE PRECIPITACAO
VALIDO PARA JUNHO DE 2019



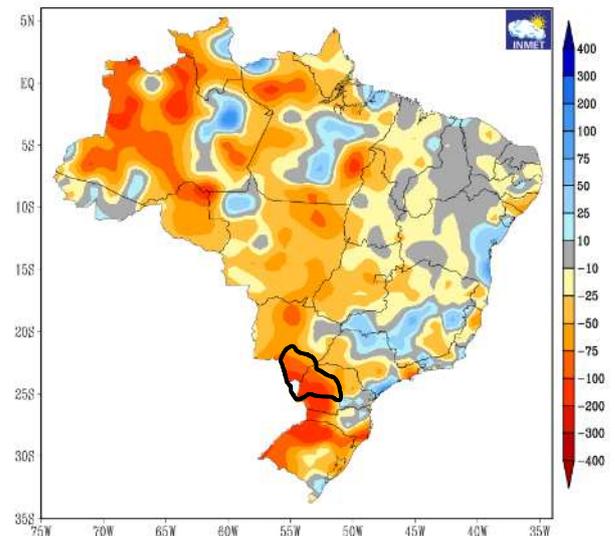
ANOMALIA DE PRECIPITACAO
VALIDO PARA JULHO DE 2019



ANOMALIA DE PRECIPITACAO
VALIDO PARA AGOSTO DE 2019



ANOMALIA DE PRECIPITACAO
VALIDO PARA SETEMBRO DE 2019



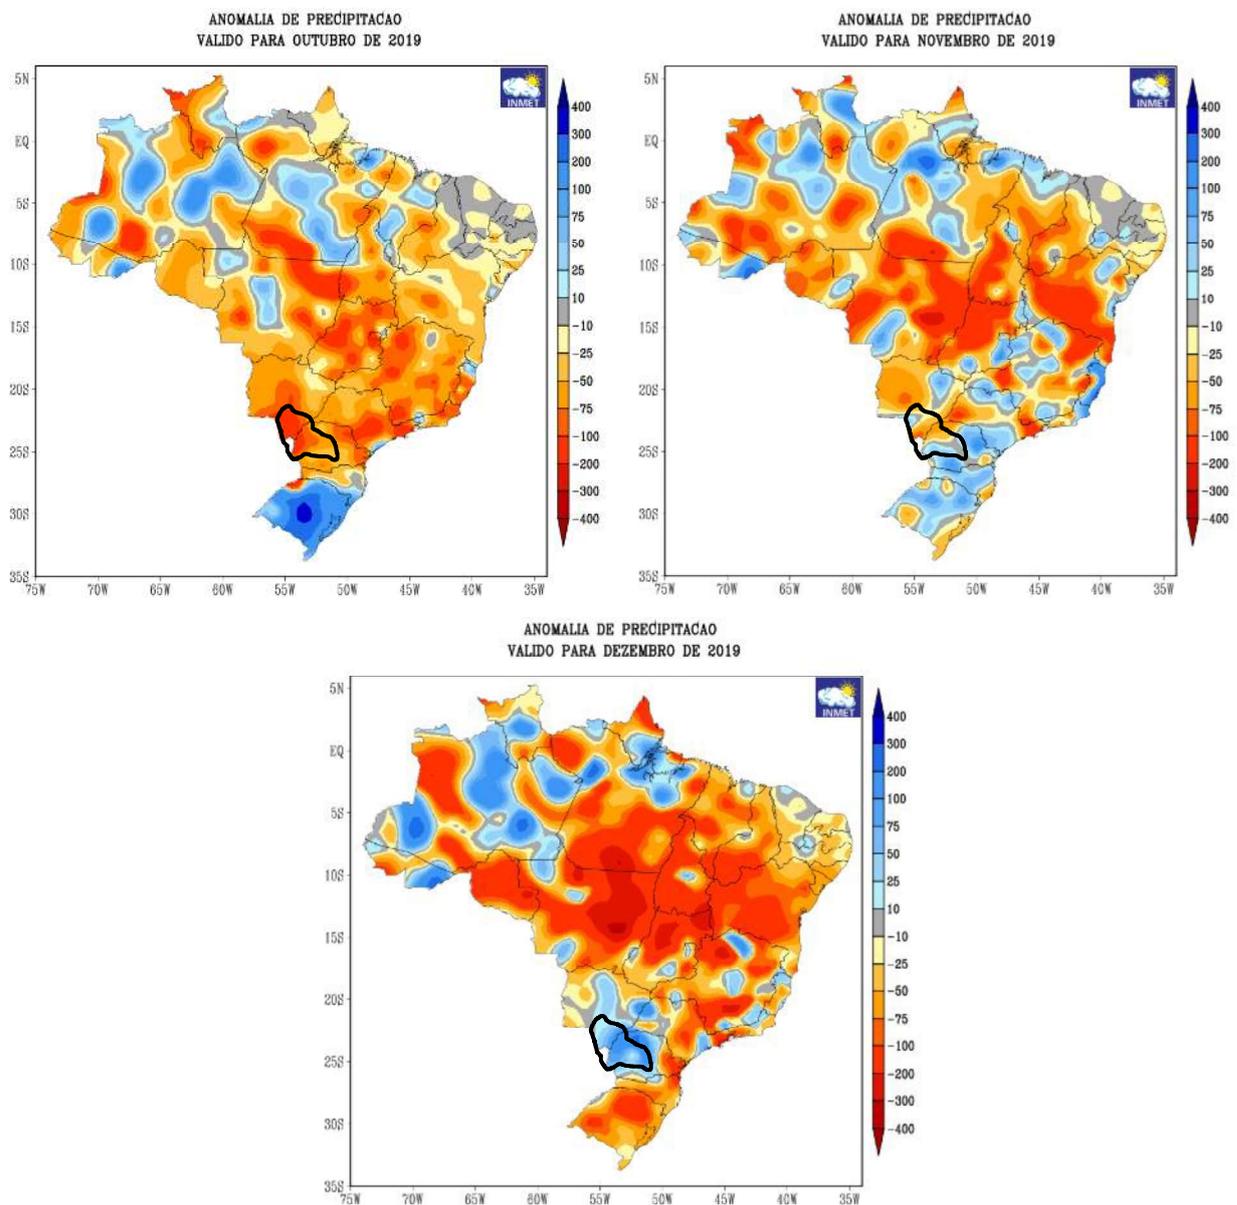


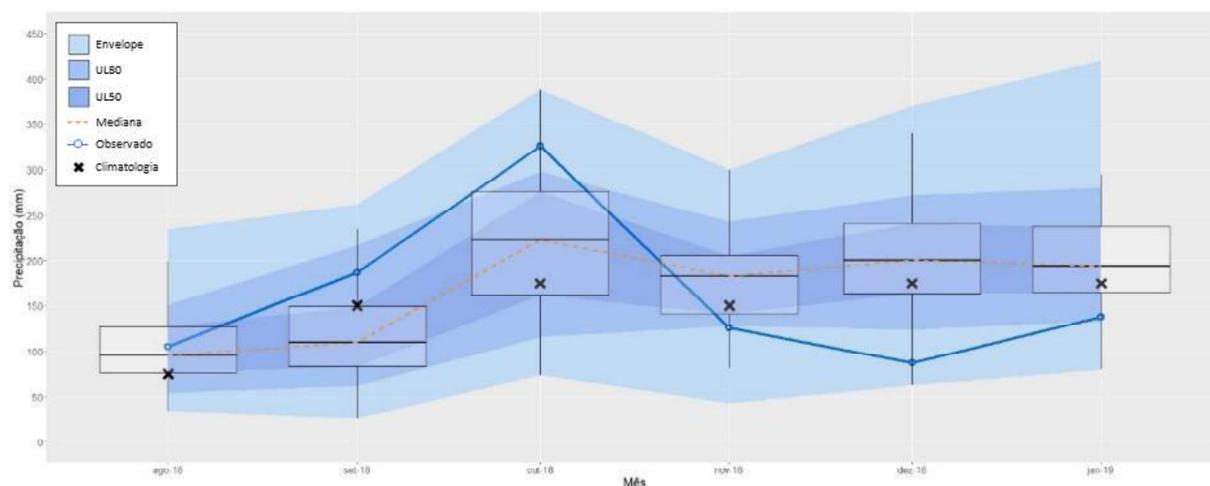
Figura 5.79 - Mapas de anomalias das precipitações média mensais dos meses avaliados nas previsões hidrológicas, com destaque para a bacia incremental de Itaipu (Fonte: INMET, 2021).

A análise dos resultados de desempenho das previsões hidrológicas da Figura 5.75 e dos mapas da Figura 5.79 permite inferir que, nos meses em que essas previsões apresentaram piores desempenhos (dezembro/2018, janeiro-fevereiro/2019, abril/2019, junho-novembro/2019), as precipitações registradas na maior parte da bacia incremental estiveram abaixo das respectivas médias históricas. Avaliando-se os gráficos da Figura 5.61 até a Figura 5.72, percebe-se uma tendência de superestimação das previsões hidrológicas para a bacia incremental nesses meses, o que poderia ser um indício de as previsões climáticas tenderem à própria climatologia.

Nesse sentido, para avaliar puramente o desempenho das previsões climáticas do C3S/SEAS5, os valores de precipitação previstos pelo *ensemble* foram comparado aos valores observados de precipitação média na bacia incremental, estimados a partir da média aritmética simples dos postos pluviométricos nela inseridos (vide Tabela 4.1 e Figura 4.3).

Assim, semelhantemente às previsões hidrológicas, foram extraídos do *ensemble* de previsões climáticas (51 membros) o primeiro, segundo e terceiro quartis, os quantis $Q_{0,10}$ e $Q_{0,90}$ e os envelopes dos valores máximos e mínimos para cada mês do horizonte previsto. Também foram destacados os correspondentes valores da climatologia para os meses previstos, a serem utilizados como referência nas análises; tais valores foram estimados visualmente a partir dos mapas das normais climatológicas de precipitação mensal ilustrados na Figura 4.2.

Os gráficos da Figura 5.80 até a Figura 5.91 ilustram os resultados obtidos. Neles, podem ser visualizadas as séries de precipitação média observada na bacia incremental ao longo do horizonte previsto (linha sólida com pontos); os valores médios estimados da climatologia mensal de precipitação (marcadores em forma de “x”); a mediana das previsões, como medida de tendência central (linha tracejada); e os limites UL_{50} , UL_{80} e envelopes (máximos e mínimos) das previsões (áreas hachuradas).



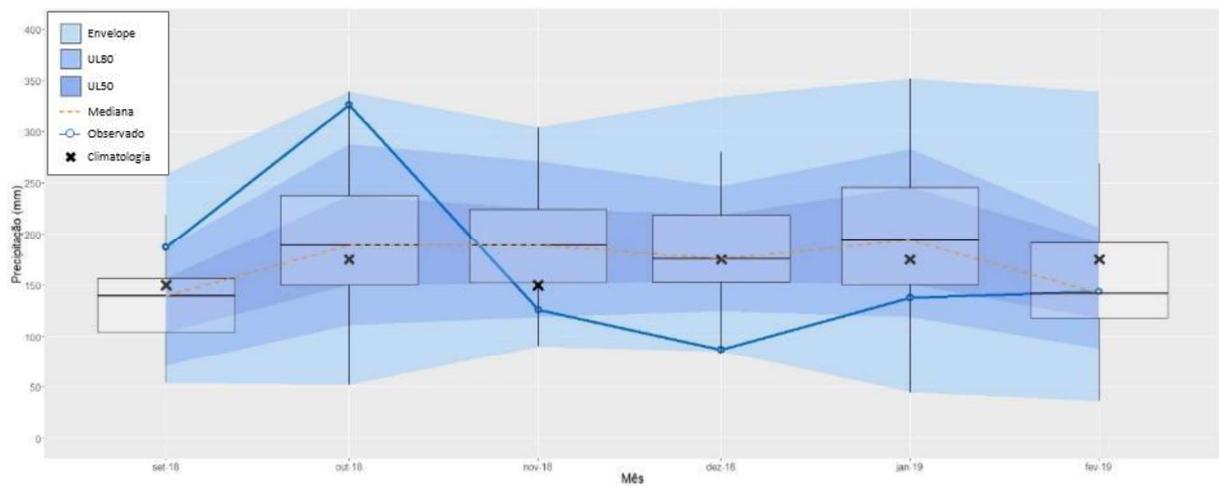


Figura 5.81 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em setembro/2018.

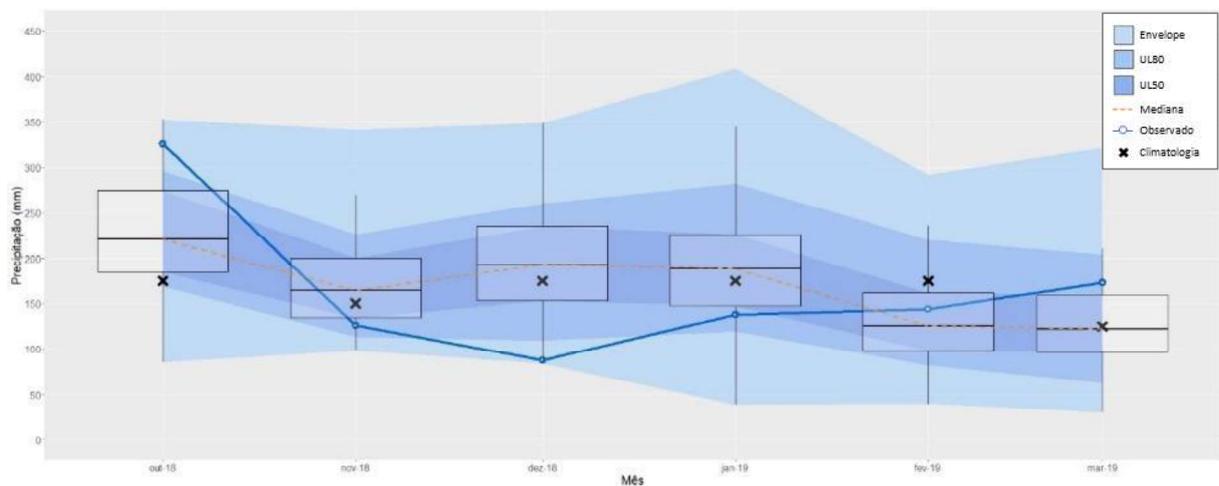


Figura 5.82 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em outubro/2018.

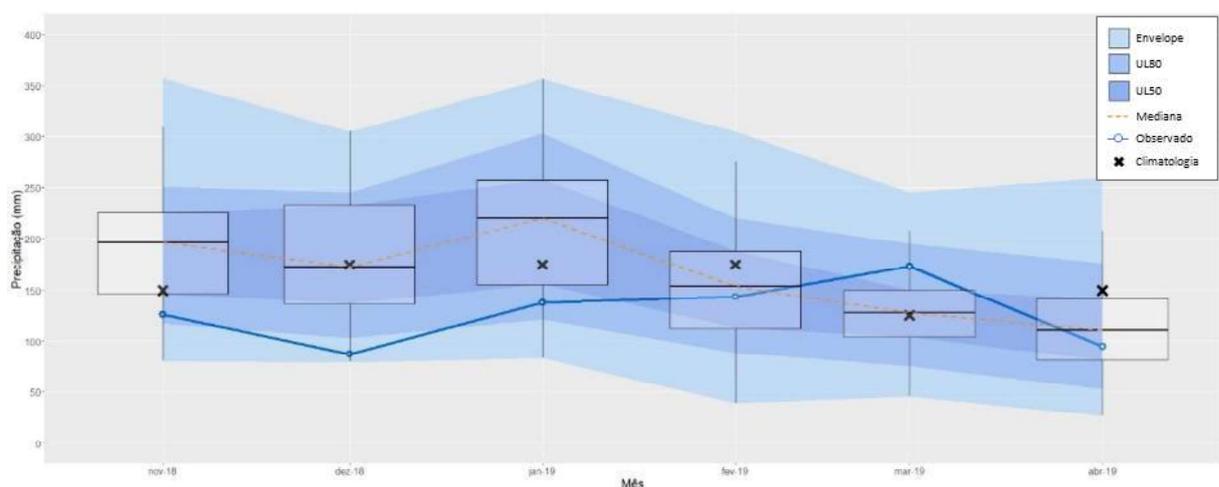


Figura 5.83 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em novembro/2018.

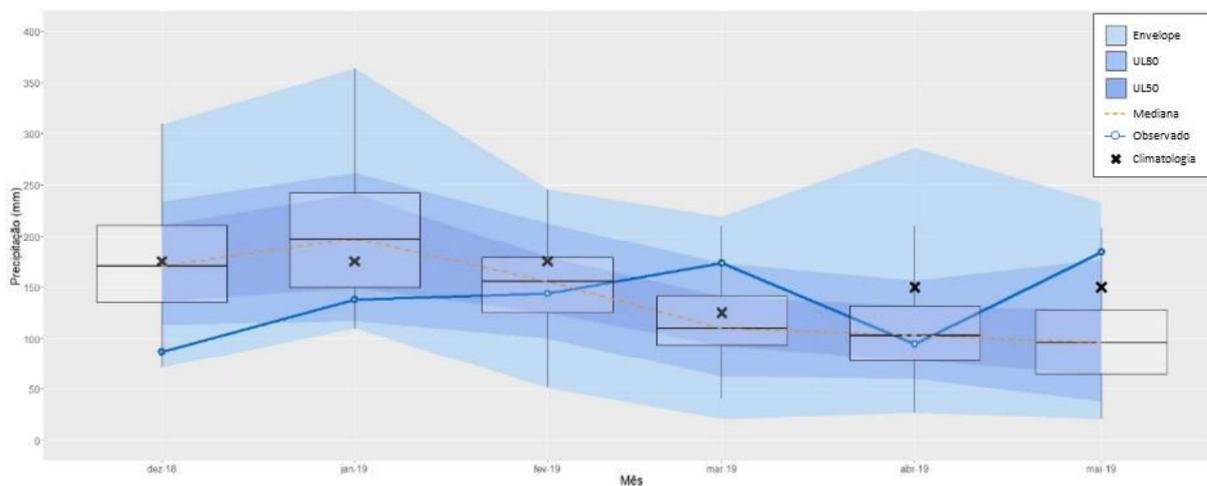


Figura 5.84 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em dezembro/2018.

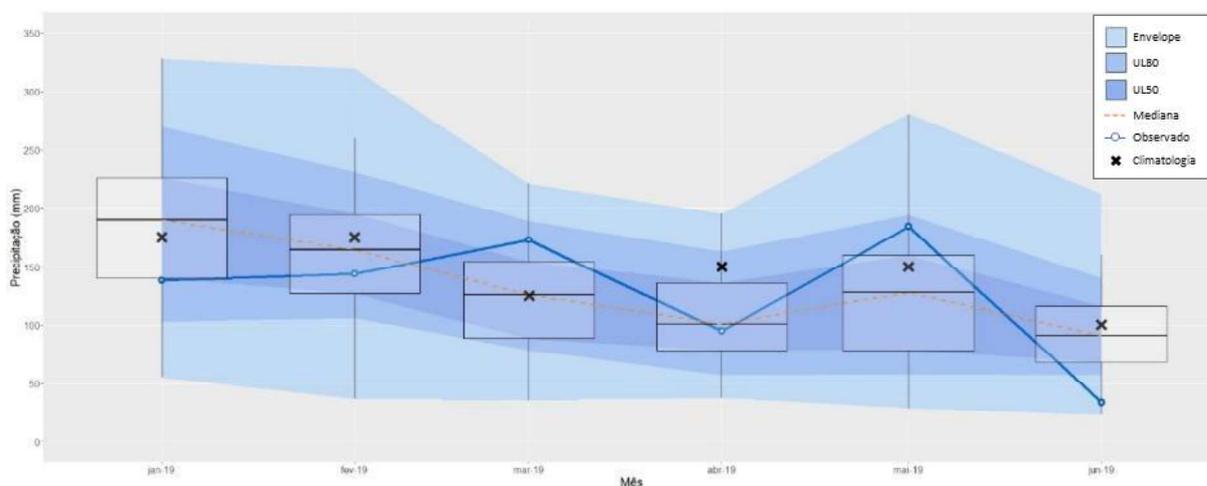


Figura 5.85 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em janeiro/2019.

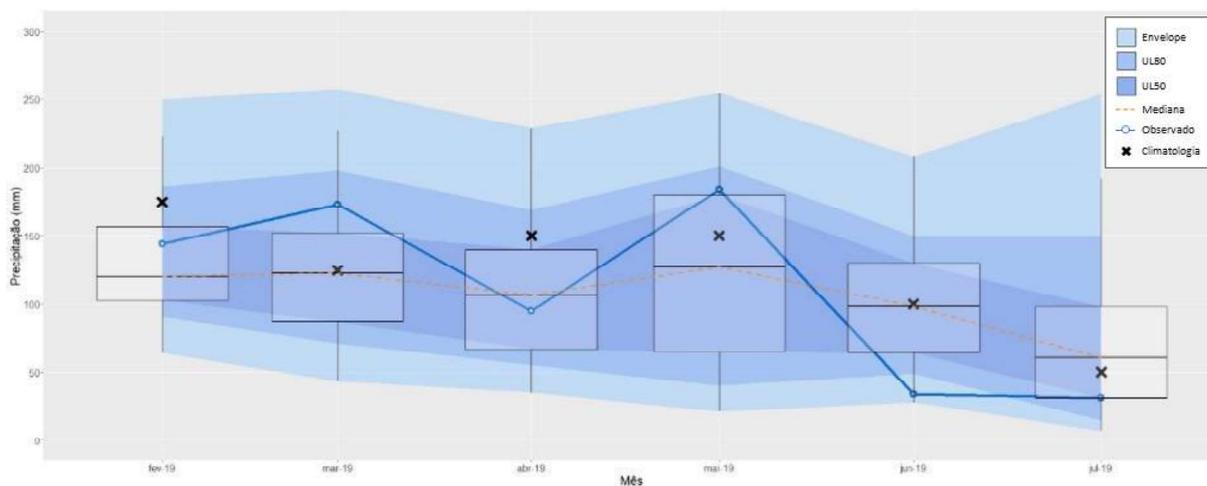


Figura 5.86 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em fevereiro/2019.

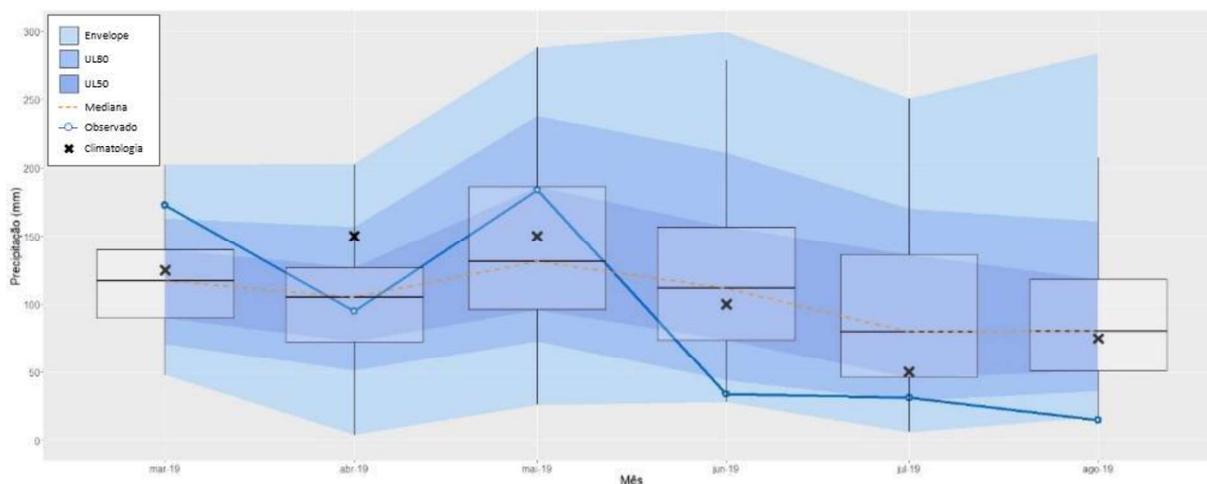


Figura 5.87 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em março/2019.

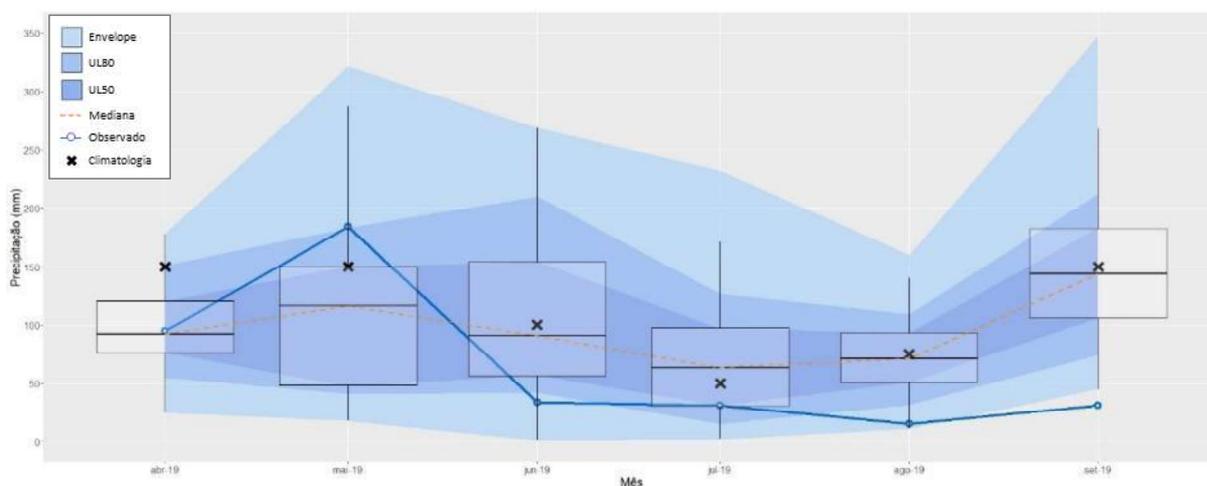


Figura 5.88 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em abril/2019.

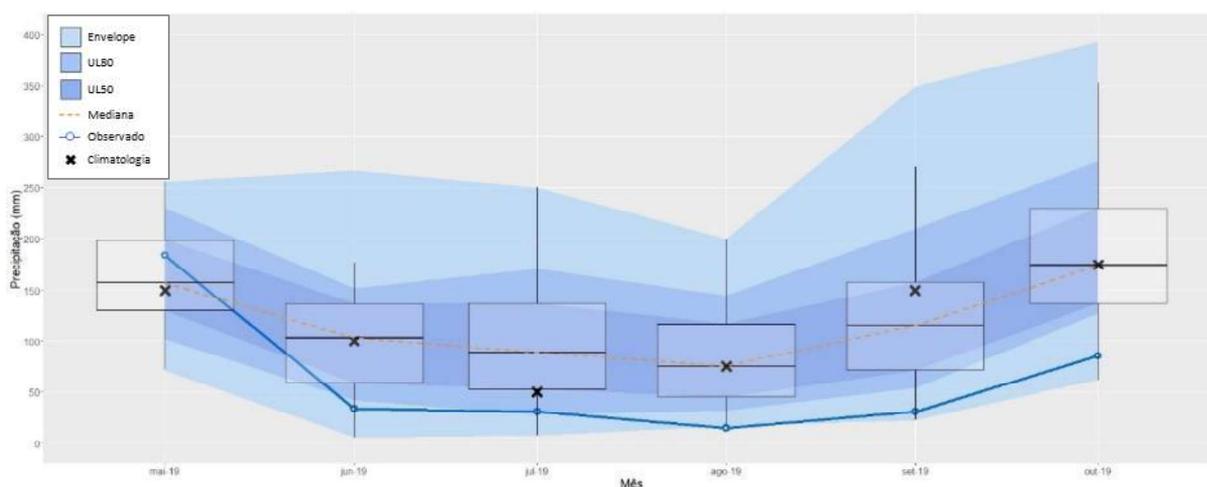


Figura 5.89 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em maio/2019.

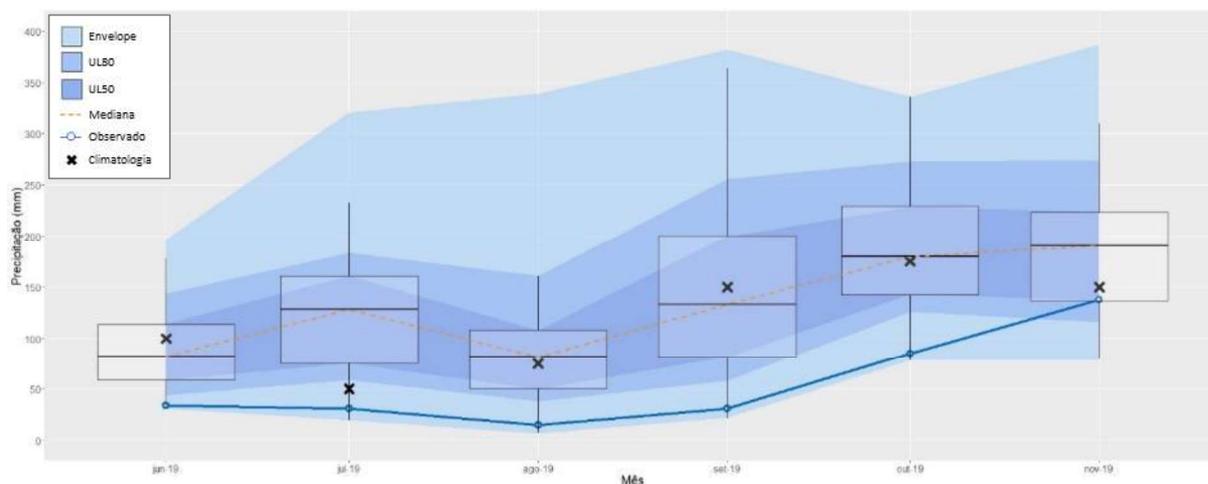


Figura 5.90 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em junho/2019.

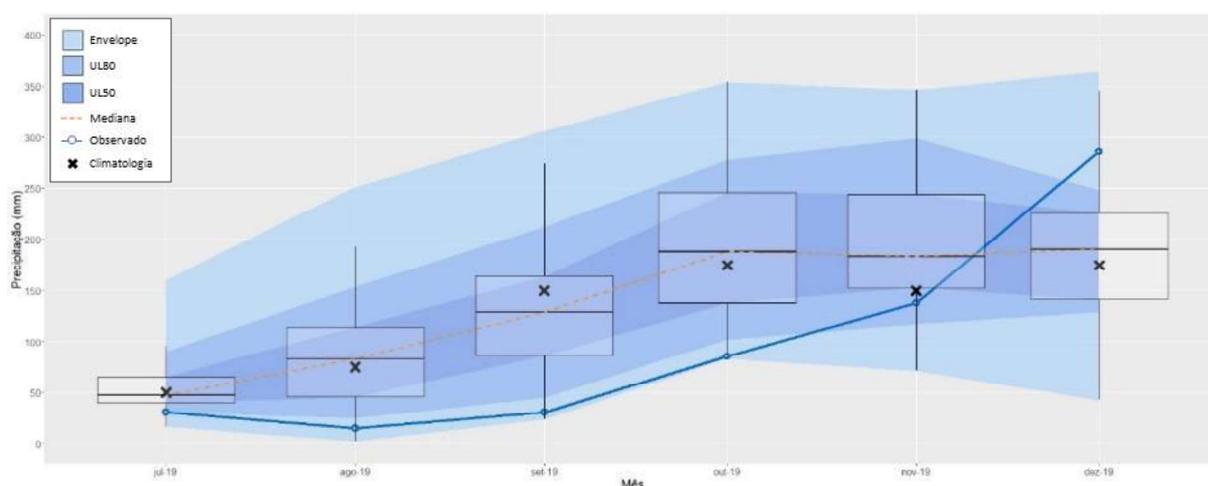


Figura 5.91 - Série de precipitações médias observadas e previsão probabilística das precipitações sobre a bacia incremental, para a previsão iniciada em julho/2019.

Dos gráficos de previsão probabilística dos volumes de precipitação mensal, observa-se que:

- Os envelopes das previsões (valores máximos e mínimos) são bastante largos, com amplitudes que ultrapassam 300 mm em alguns meses, e refletem a incerteza acerca da precipitação futura de meses à frente. Em função dessa grande amplitude, esses envelopes conseguem capturar a variabilidade da chuva observada em todas as 12 séries analisadas, ainda que, na maioria dos meses, tenham previsto baixas probabilidades para os valores;
- Observa-se que os valores mais prováveis dessas previsões tendem a se concentrar em torno dos valores de referência (médias climatológicas) e, desse modo, superestimar a precipitação futura nos meses em que foram registradas anomalias negativas de precipitação, e subestimar nos meses em que foram registradas anomalias positivas;

- Percebe-se uma certa “inércia” acerca das previsões de precipitação, dado que não há grande variabilidade dos valores previstos de uma previsão para a outra. Isso reflete a maior interdependência destas previsões a componentes de evolução lenta do sistema climático (e.g. a TSM) do que à persistência das precipitações observadas em meses anteriores.

Avaliando-se os resultados em termos determinísticos, a partir da mediana (medida de tendência central) da distribuição de probabilidades dessas previsões, foram gerados os gráficos da Figura 5.92 até a Figura 5.94, e as correspondentes tabelas (Tabela 5.12 à Tabela 5.15):

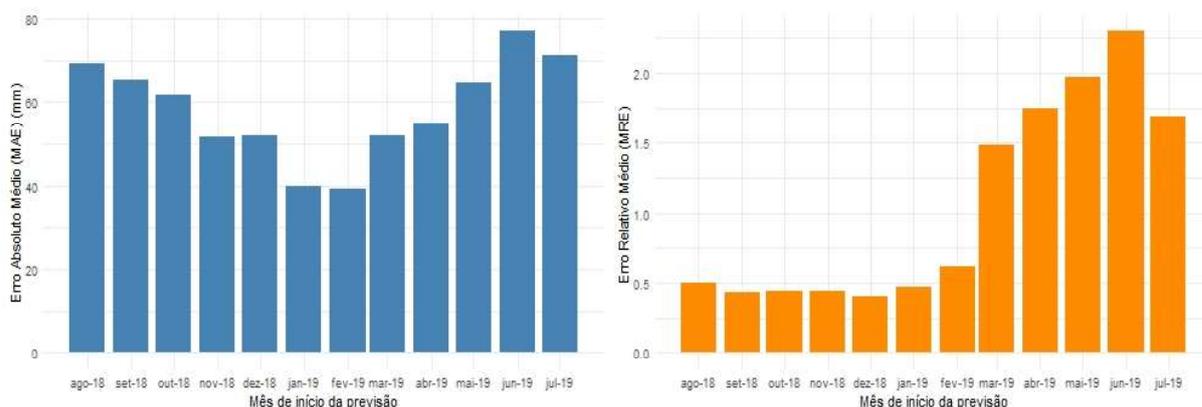


Figura 5.92 - Desempenho global (MAE e MRE) da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, para cada mês de início da previsão.

Tabela 5.12 - Desempenho global (MAE e MRE) da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, para cada mês de início da previsão.

Início da previsão	MAE (mm)	MRE
ago-18	69	0,50
set-18	66	0,43
out-18	62	0,44
nov-18	52	0,44
dez-18	52	0,40
jan-19	40	0,47
fev-19	39	0,62
mar-19	52	1,49
abr-19	55	1,75
mai-19	65	1,97
jun-19	77	2,31
jul-19	71	1,69

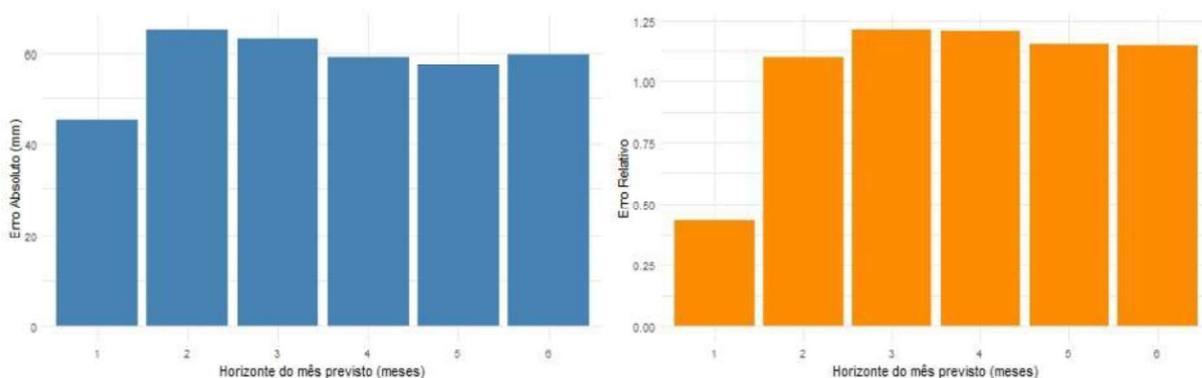


Figura 5.93 - Desempenho geral da mediana da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, para cada horizonte do mês previsto.

Tabela 5.13 - Desempenho geral da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, para cada horizonte do mês previsto.

Mês Previsto	MAE (mm)	MRE
1 ^o *	45	0,43
2 ^o	65	1,10
3 ^o	63	1,21
4 ^o	59	1,21
5 ^o	58	1,15
6 ^o	60	1,14

* O 1^o mês previsto é o próprio mês de início da previsão.

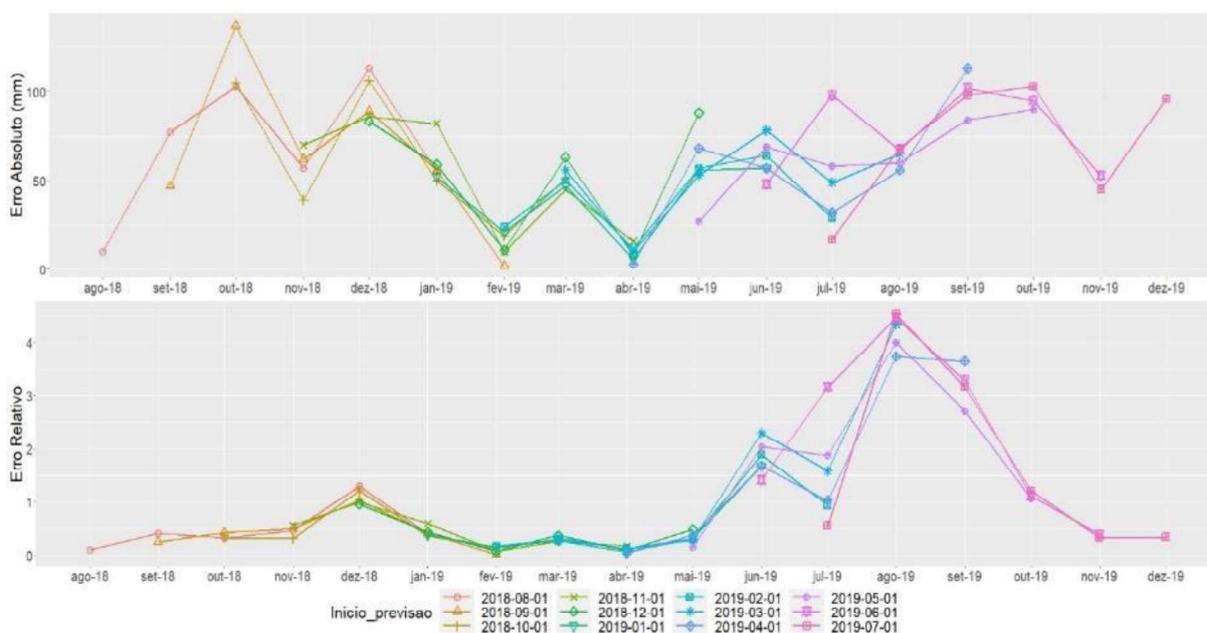


Figura 5.94 - Evolução do desempenho da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.

Tabela 5.14 - Evolução do erro absoluto médio (MAE) da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.

Mês previsto	MAE (mm) para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	10	47	105	70	83	52	24	56	3	27	48	17
2 ^o	77	137	39	86	59	21	50	10	68	69	98	68
3 ^o	103	62	106	82	11	47	12	53	57	58	67	98
4 ^o	57	89	50	10	63	6	57	78	32	60	102	103
5 ^o	113	56	19	45	8	56	64	49	56	84	95	45
6 ^o	55	2	51	16	88	57	29	65	113	90	53	96

* O 1^o mês previsto é o próprio mês de início da previsão.

Tabela 5.15 - Evolução do erro relativo médio (MRE) da mediana do *ensemble* de cada série de previsão de precipitação sobre a bacia incremental, mês a mês.

Mês previsto	MRE para previsão iniciada em:											
	ago-18	set-18	out-18	nov-18	dez-18	jan-19	fev-19	mar-19	abr-19	mai-19	jun-19	jul-19
1 ^o *	0,10	0,25	0,32	0,56	0,95	0,38	0,17	0,32	0,03	0,15	1,41	0,55
2 ^o	0,41	0,42	0,31	0,99	0,43	0,15	0,29	0,11	0,37	2,03	3,16	4,53
3 ^o	0,32	0,49	1,22	0,59	0,08	0,27	0,13	0,29	1,68	1,87	4,47	3,16
4 ^o	0,45	1,02	0,36	0,07	0,36	0,06	0,31	2,29	1,03	4,00	3,29	1,21
5 ^o	1,30	0,41	0,13	0,26	0,08	0,30	1,88	1,58	3,73	2,71	1,12	0,33
6 ^o	0,40	0,01	0,29	0,17	0,48	1,68	0,94	4,33	3,65	1,06	0,38	0,34

* O 1^o mês previsto é o próprio mês de início da previsão.

Desses resultados, percebe-se a importante redução de previsibilidade a partir do segundo mês de previsão de precipitação. Além disso, é possível observar a dificuldade das previsões climáticas na representação das precipitações ocorridas entre junho/2019 e outubro/2019, em que foram registradas anomalias de precipitação significativamente negativas sobre a bacia incremental. Nessas previsões, os erros relativos obtidos estiveram acima dos 100% em praticamente todos os meses previstos, e chegaram a alcançar os 453% no mês de agosto/2019.

Avaliando-se apenas o desempenho da medida de tendência central (mediana) da distribuição de probabilidade das previsões climáticas, poder-se-ia concluir que o C3S/SEAS5 apresenta

baixa previsibilidade para as precipitações sobre a região estudada. No entanto, ao se avaliar qualitativamente o espalhamento do *ensemble* de suas previsões (Figura 5.80 à Figura 5.91), observa-se que este consegue capturar a variabilidade da chuva sobre a bacia. Isso demonstra a importância da consideração das incertezas acerca das condições de inicialização das previsões climáticas, e as vantagens do uso de previsões probabilísticas em lugar das determinísticas (aqui representadas pela mediana do *ensemble* e pela climatologia).

A fim de se avaliar quantitativamente as previsões probabilísticas de precipitação, foi feita a análise de seus desempenhos em termos de erro médio, destreza e confiabilidade. Para o cálculo das métricas *Brier Score* e *Brier Skill Score*, os três limiares de precipitação média mensal também foram definidos como 70%, 60% e 50% de permanência da série histórica utilizada na calibração, equivalentes a 89 mm, 109 mm e 130 mm, respectivamente. A destreza das dessas previsões foi avaliada utilizando como referência tanto a mediana das previsões, quanto os valores estimados das médias climatológicas.

Observa-se na Figura 5.95 que, semelhantemente à mediana das previsões (Figura 5.93), os erros médios, representados pelos valores de BS, tendem a aumentar do primeiro ao quarto mês do horizonte previsto, mas há uma redução destes a partir do quinto mês. Ademais, observa-se um melhor desempenho das previsões probabilísticas em estimar a ocorrência dos menores limiares de precipitação nos primeiros quatro meses do horizonte previsto, mas a partir do quinto mês o desempenho tende a ser melhor para o limiar superior, de 130 mm.

Quanto à destreza das previsões probabilísticas em relação à mediana das previsões (Figura 5.96A), para o maior limiar de precipitação (130 mm) o desempenho daquelas foi superior ao desta ao longo de todo o horizonte previsto. Para o menor limiar (89 mm), a mediana apresentou melhor desempenho no primeiro mês do horizonte; e para o limiar intermediário (109 mm), o desempenho desta foi superior nos três primeiros meses previstos.

Em relação à climatologia (Figura 5.96B), para o maior limiar de precipitação também se observa um desempenho superior das previsões probabilísticas para todo o horizonte previsto. Já para os demais limiares, a climatologia apresenta melhor desempenho no segundo mês do horizonte. De fato, conforme anteriormente observado para as medianas das previsões (Figura 5.93), há uma importante redução da previsibilidade a partir do segundo mês previsto. Entretanto, as previsões probabilísticas voltaram a apresentar melhor desempenho do terceiro

mês em diante, evidenciando os benefícios de uso destas em prol de se utilizarem as médias climatológicas como estimativa de precipitações futuras.

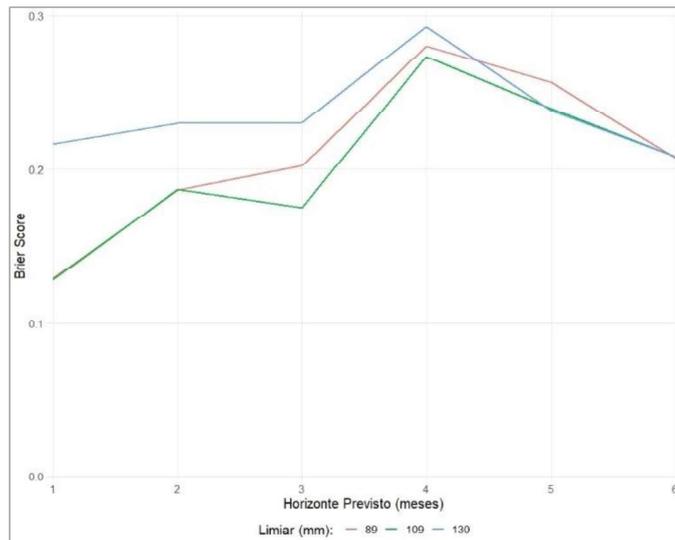


Figura 5.95 - Evolução do BS das previsões probabilísticas precipitação sobre a bacia incremental, para cada horizonte do mês previsto.

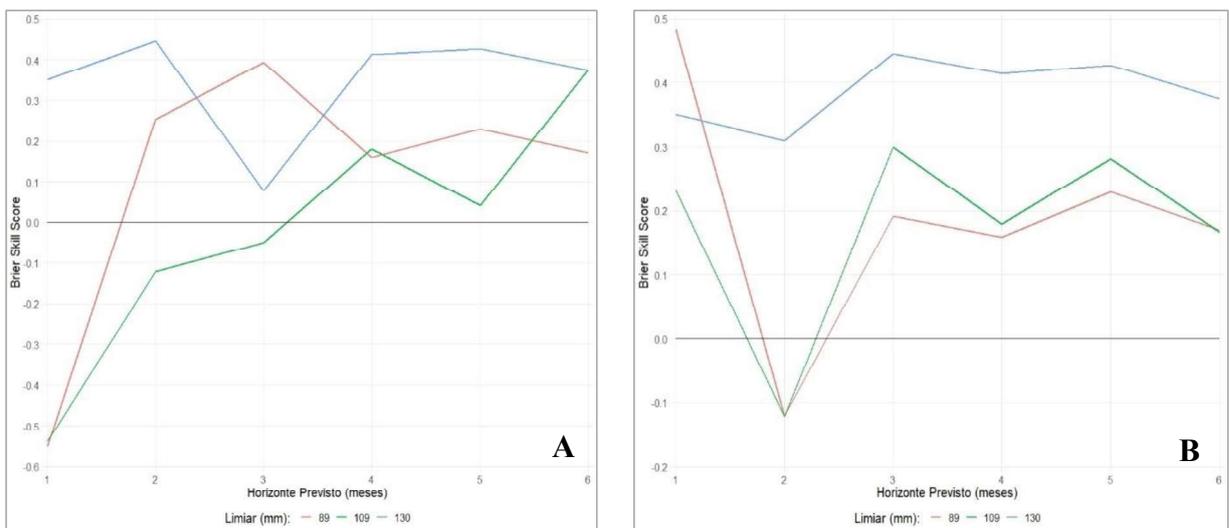
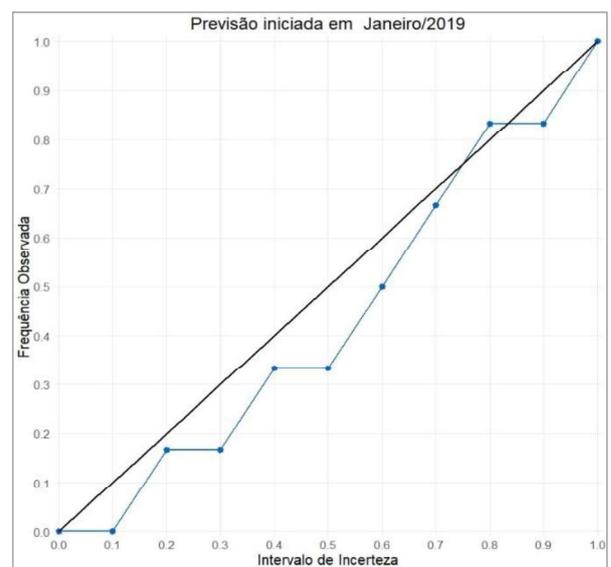
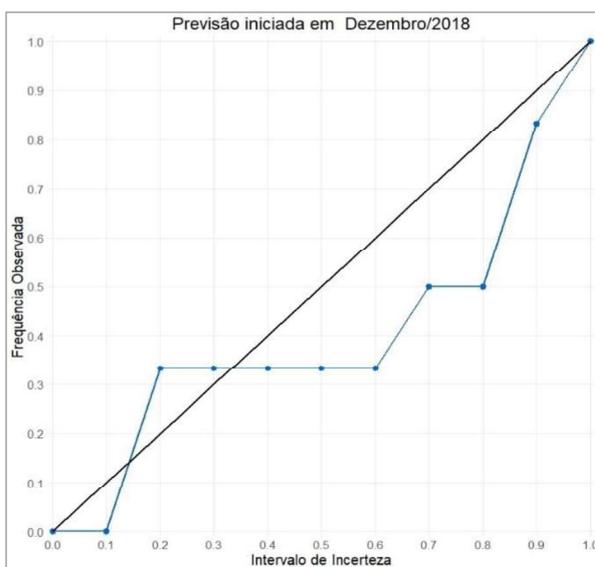
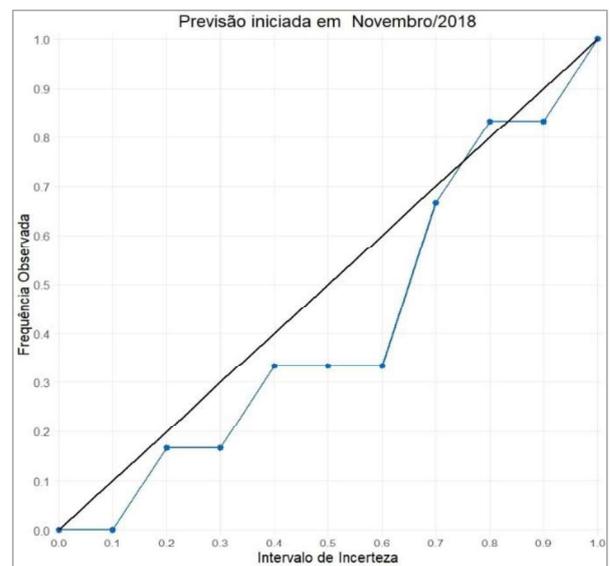
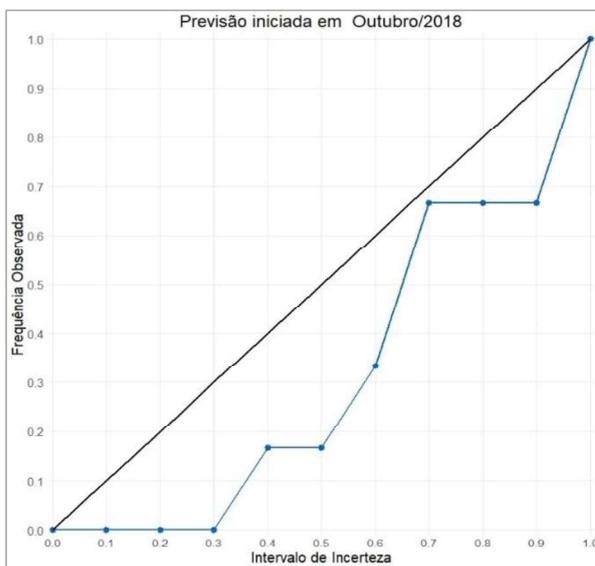
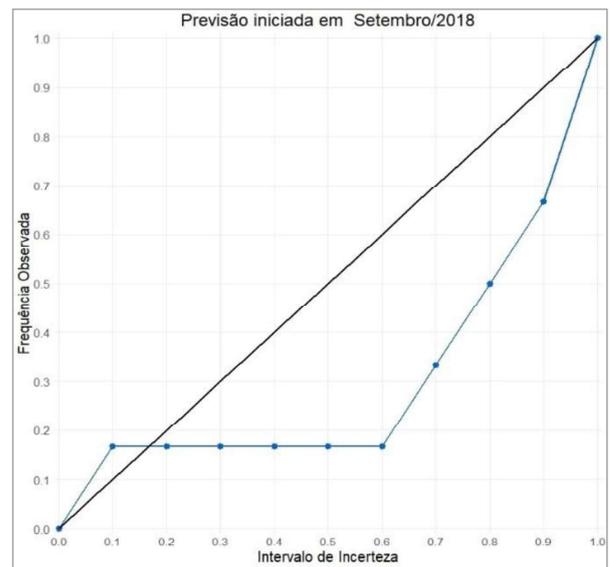
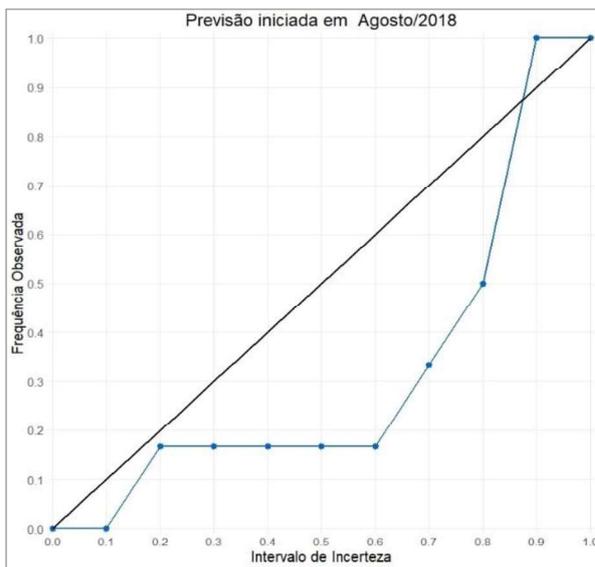


Figura 5.96 - Evolução do BSS das previsões probabilísticas de precipitação sobre a bacia incremental para cada horizonte do mês previsto, em relação (A) à mediana das previsões, (B) à climatologia.

Por fim, para a avaliação da confiabilidade dos limites de incerteza do *ensemble* de previsões precipitação, foram extraídos, além dos UL's de 50% e 80% apresentados nos gráficos da Figura 5.80 à Figura 5.91, os demais limites variando de 0% a 100%. A partir desses UL's, foram contabilizados os percentuais das observações neles inseridos. Os diagramas resultantes dessa avaliação encontram-se agrupados na Figura 5.97.



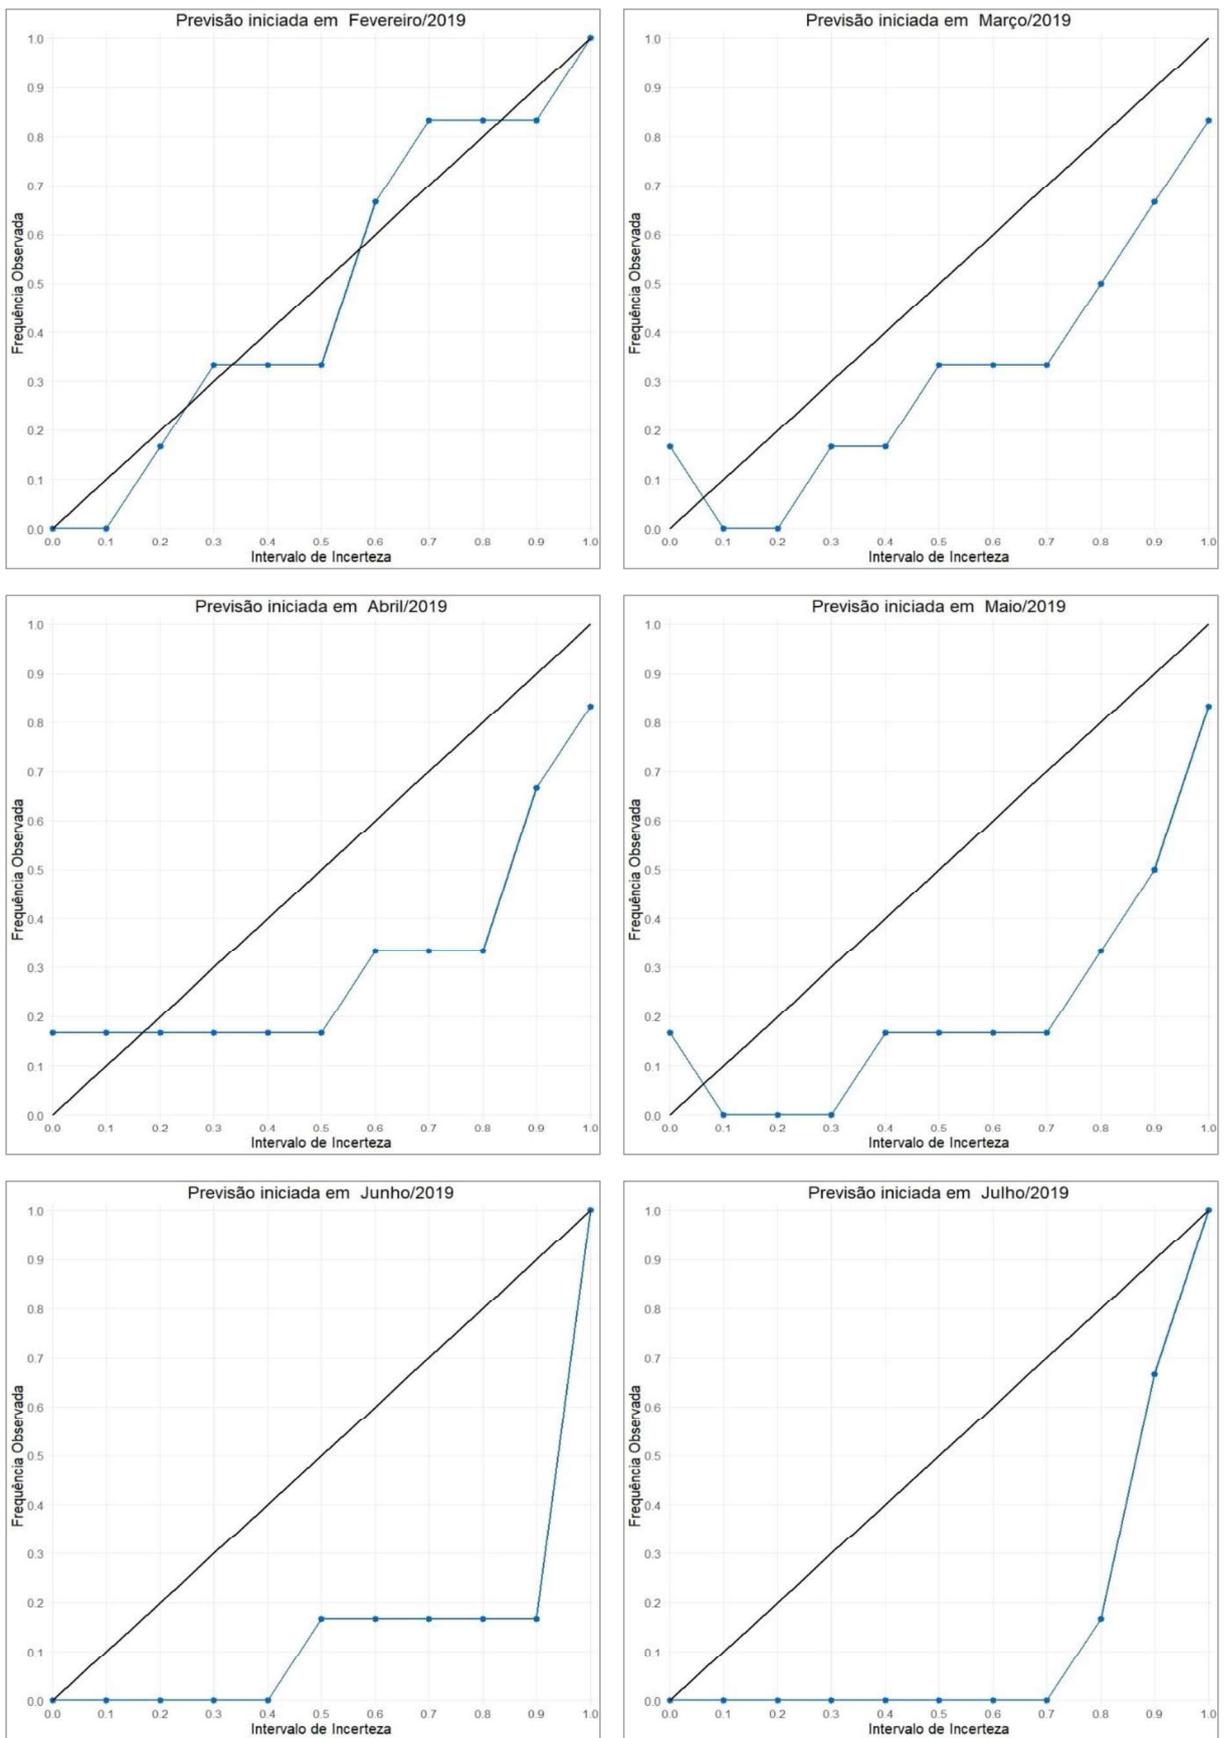


Figura 5.97 - Diagramas de avaliação da confiabilidade dos limites de incerteza das previsões de vazão incremental à Itaipu (linha 1:1 para referência).

Desses diagramas, observa-se uma boa confiabilidade dos limites de incerteza das previsões de precipitação iniciadas entre os meses de novembro/2019 e fevereiro/2019, uma vez que os valores tendem a se aproximar da linha 1:1 de referência. Isso corrobora os resultados obtidos tanto para a mediana das previsões de precipitação (Figura 5.92), quanto para a mediana das previsões de vazão da bacia incremental (Figura 5.73), indicando uma maior confiabilidade das previsões para aqueles meses em que os volumes precipitados geralmente são menores.

Para as demais previsões, os limites de incerteza calculados tendem a superestimar a probabilidade de ocorrência das observações na maior parte do tempo, tal como observado nos diagramas das previsões de vazão para a bacia incremental (Figura 5.78). No entanto, a confiabilidade das envoltórias máximas e mínimas de incerteza foi superior nas previsões de precipitação, uma vez que apenas nas previsões iniciadas em março/2019, abril/2019 e maio/2019 essas envoltórias não conseguiram capturar a variabilidade das observações, enquanto que nas previsões hidrológicas isso ocorreu para quase todas as séries de previsão, exceto para aquela iniciada em dezembro/2018.

Em virtude disso, constata-se que a variabilidade das precipitações previstas pelas previsões climáticas não é bem reproduzida pelo modelo hidrológico. Isso indica a existência de uma limitação estrutural do SMAP e/ou da metodologia adotada para a estimação de incertezas do modelo e para a assimilação de dados. Desse modo, os erros acabam sendo propagados ao longo da estrutura do modelo, o que conseqüentemente prejudica a representação da resposta hidrológica das bacias a essas precipitações futuras.

6 CONCLUSÕES E RECOMENDAÇÕES

O presente trabalho teve como principal objetivo o desenvolvimento de um sistema simplificado para previsão probabilística de aflúências mensais ao reservatório da Usina Hidrelétrica de Itaipu, à qual foram incorporadas as incertezas associadas à previsão climática de precipitação do ECMWF, assim como as incertezas inerentes ao próprio modelo hidrológico utilizado.

Para alcançar esse objetivo, ao longo da pesquisa realizou-se uma série de opções metodológicas, fundamentadas na busca por técnicas conceitualmente simples e que fossem capazes de reproduzir o produto alvo do trabalho: a previsão de longo prazo de aflúências médias mensais ao reservatório da Usina Hidrelétrica de Itaipu.

Nesse sentido, optou-se pelo uso do modelo SMAP, um modelo hidrológico simplificado e parcimonioso já conhecido no setor elétrico brasileiro e atualmente utilizado pelo Operador Nacional do Sistema. Além disso, apesar das controvérsias e das limitações apontadas pela literatura, o método GLUE, para a estimação das incertezas paramétricas e de estado do modelo, foi escolhido pela simplicidade de aplicação e por não exigir a implementação de um modelo de erros. Tal método foi aprimorado a partir da incorporação de um procedimento simplificado de assimilação de dados no instante imediatamente anterior ao da previsão hidrológica, levando-se em consideração o erro observacional do modelo hidrológico. Por fim, as previsões de precipitação de longo prazo elaboradas pelo ECMWF foram escolhidas pelos bons resultados já reconhecidos pela literatura atual.

O desempenho das previsões resultantes do sistema desenvolvido foi avaliado, a fim de se averiguar a viabilidade de sua operacionalização para previsões em tempo real das aflúências à UHE Itaipu. A amostra de previsões analisadas, de apenas doze séries, é bastante reduzida para a generalização das conclusões aqui discutidas. Essa limitação amostral está relacionada à grande quantidade de dados necessária às simulações e ao longo tempo de processamento de toda a informação, para que fosse feita uma avaliação mais ampla dos resultados. No entanto, acredita-se que os resultados obtidos dessa reduzida amostra são úteis como uma primeira avaliação da potencialidade do uso do sistema desenvolvido como ferramenta para a previsão hidrológica de longo prazo das aflúências ao reservatório de Itaipu.

Das previsões resultantes desse sistema de previsões, pode-se concluir que:

- O sistema desenvolvido mostrou-se potencialmente útil como ferramenta operacional de previsão, dado que possibilita a geração de previsões probabilísticas de afluência ao reservatório de Itaipu a partir da estimação das incertezas a elas associadas. Desse modo, os resultados dessas previsões podem ser considerados cientificamente mais corretos e permitem ao tomador de decisões ter a informação de forma mais ampla e fazer, assim, uma avaliação de riscos e o gerenciamento de controle em função dos possíveis cenários hidrológicos futuros. No entanto, uma possível limitação da operacionalização desse sistema é o tempo de processamento necessário para a obtenção das previsões, em função do grande número de parâmetros simulados e de possíveis combinações para a afluência prevista. Posteriores melhorias nos algoritmos e reduções no número de simulações de Monte Carlo poderiam otimizar esse tempo de processamento.
- Em termos de medida central, as previsões probabilísticas de afluência à Itaipu obtidas demonstraram um bom desempenho, dado que a mediana dessas séries apresentou erros relativos médios inferiores aos 10% para a previsão de um até três meses à frente, e inferiores a 20% do 4º ao 6º mês previsto. Já a avaliação probabilística indicou um melhor desempenho das previsões por conjunto em relação à previsão determinística de referência (mediana) na maior parte do tempo. Ademais, observou-se que os limites de incerteza obtidos do *ensemble* de previsões tendem a superestimar a probabilidade de ocorrência das observações, e que as envoltórias máximas e mínimas dessas previsões geralmente possuem baixa confiabilidade.
- Dado que o desempenho das previsões de afluência à Itaipu é substancialmente influenciado pela consideração das defluências observadas das usinas localizadas à montante, para uma análise mais realista dos resultados foram também avaliadas as previsões hidrológicas de vazão natural da bacia incremental de Itaipu. A partir das medidas de tendência central (mediana) dessas previsões, foram obtidos erros relativos médios de até 50% para previsões de um a três meses à frente, e de até 102% do 4º ao 6º mês previsto, significativamente superiores aos das previsões de afluência à UHE Itaipu. Quanto à avaliação probabilística das previsões de vazão incremental por *ensemble*, observou-se um desempenho superior destas em relação à previsão determinística de referência (mediana) ao longo de todo horizonte previsto, o que evidencia as vantagens de uso das previsões por conjunto em lugar das previsões determinísticas, representadas pela mediana das previsões.

- Com a finalidade de se avaliar a existência de possíveis vieses nas previsões climáticas puramente, estas foram comparadas às médias de precipitação observadas na bacia incremental. Assim, a partir das doze séries analisadas, percebeu-se que uma tendência de as previsões se aproximarem dos valores de precipitação da climatologia e, conseqüentemente, de subestimarem as precipitações em meses mais chuvosos do que a média (anomalias positivas), e de superestimarem em meses mais secos do que a média (anomalias negativas). Nesse sentido, um método de correção desses erros sistemáticos (vieses) das previsões poderia ser aplicado para aprimorar-se o seu desempenho.
- Ainda assim, o *ensemble* das previsões climáticas brutas foi capaz de capturar as precipitações observadas em todas as doze séries analisadas, uma vez que os limites máximos e mínimos (envelopes) do *ensemble* apresentam grande amplitude, em função da alta incerteza acerca das precipitações futuras de longo prazo. Ademais, quando avaliadas em formato probabilístico, o uso dessas previsões supera os valores de referência (médias climatológicas), corroborando a hipótese de que as previsões climáticas são viáveis de serem utilizadas para a previsão probabilística de vazões para meses à frente. No entanto, reitera-se que a amostra aqui avaliada é muito pouco representativa para caracterizar a previsibilidade das previsões do C3S/SEAS5, sendo fortemente recomendada a avaliação de previsões elaboradas em diferentes contextos climáticos de grande escala, para analisar a destreza do modelo climático na escala interanual.
- Destaca-se a importância da consideração de outras formas de incerteza além das associadas à previsão de precipitação. No presente trabalho, mesmo com a consideração das incertezas acerca do modelo hidrológico utilizado, não foi possível contemplar toda a variabilidade das vazões nos limites de incerteza previstos. Desse modo, a utilização de outras funções de verossimilhança e de seus respectivos limites de corte, como também de outros métodos de estimação de incerteza e/ou de outros modelos hidrológicos (ou mesmo a combinação de vários modelos, por exemplo a partir do uso de técnicas como o BMA), seria importante para a avaliação dos correspondentes impactos no desempenho das previsões hidrológicas. Ademais, outras previsões de precipitação poderiam ser apreciadas, assim como combinações de previsões de diferentes centros de meteorologia (por exemplo, utilizando *ensembles multimodel*). Estas, assim como outras avaliações podem, portanto, fazer parte de estudos futuros e complementares a esta pesquisa.

- Por fim, recomenda-se a avaliação de amostras maiores de previsões, para que os resultados obtidos sejam mais abrangentes e englobem outros possíveis contextos hidrológicos e climáticos. Ainda que pouco representativa, a amostra avaliada ao longo deste trabalho permitiu demonstrar as vantagens do uso das previsões probabilísticas em lugar das determinísticas, as quais ainda são o formato predominante das previsões hidrológicas operacionais e que acabam criando a falsa ilusão de certeza ao usuário final da informação.

REFERÊNCIAS

- ADAMS, T. E. Flood Forecasting in the United States NOAA/National Weather Service. In: ADAMS, T. E.; PAGANO, T. C. (Eds.). *Flood Forecasting: A Global Perspective*. Academic Press: Cambridge, MA, USA, 2016. <http://dx.doi.org/10.1016/B978-0-12-801884-2.00010-4>.
- ALLEY, R. B.; EMANUEL, K. A.; ZHANG, F. Advances in weather prediction. *SCIENCE*, Vol. 363, Issue 6425, p. 342-344, 2019. DOI: 10.1126/science.aav7274.
- ALMEIDA, L.; SERRA, J. C. V. Modelos hidrológicos, tipos e aplicações mais utilizadas. *Revista da FAE*, Volume 20, Número 1, p. 129-137, 2017.
- ANA - AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (Brasil). *Hidroweb: Sistemas de Informações Hidrológicas*. Disponível em: <<http://www.snirh.gov.br/hidroweb/serieshistoricas>>. Acesso em: fevereiro de 2020.
- ARNAL, L.; CLOKE, H. L.; STEPHENS, E.; WETTERHALL, F.; PRUDHOMME, C.; NEUMANN, J.; KRZEMINSKI, B.; PAPPENBERGER, F. Skilful seasonal forecasts of streamflow over Europe? *Hydrology and Earth System Sciences*, Volume 22, Issue 4, 2018, p. 2057-2072. <https://doi.org/10.5194/hess-22-2057-2018>.
- BARKMEIJER, J.; BUIZZA, R.; KÄLLÉN, E.; MOLTENI, F.; MUREAU, R.; PALMER, T.; TIBALDI, S.T; TRIBBIA, J. 20 years of ensemble prediction at ECMWF. *Meteorology section of ECMWF Newsletter*, No. 134, p. 16-32, 2012.
- BARTHOLMES, J.; TODINI, E. Coupling meteorological and hydrological models for flood forecasting. *Hydrology and Earth System Sciences*, Vol. 9, p. 333-346, 2005.
- BAUER, P.; THORPE, A.; BRUNET, G. The quiet revolution of numerical weather prediction. *Nature*, Vol. 525, p. 47-55, 2015.
- BEVEN, K. J; SMITH, P. J.; FREER, J. E. So just why would a modeller choose to be incoherent? *Journal of Hydrology*, Volume 354, Issues 1-4, pg. 15-32, 2008.
- BEVEN, K. Prophecy, reality and uncertainty in distributed hydrological modelling. *Advances in Water Resources Journal*, Volume 16, Issue 1, p. 41-51, 1993.
- BEVEN, K.; BINLEY, A. The Future of Distributed Models: Model Calibration and Uncertainty Prediction. *Hydrological Processes Journal*, Volume 6, Issue 3, p. 279-298, 1992.
- BLÖSCHL, G. et al. Twenty-three Unsolved Problems in Hydrology (UPH) – a community perspective. *Hydrological Sciences Journal*, Vol. 64, No. 10, p. 1141-1158, 2019. DOI: 10.1080/02626667.2019.1620507.
- BRAVO, J. M.; ALLASIA, D. G.; COLLISCHONN, W.; TASSI, R.; MELLER, A.; TUCCI, C. E. M. Avaliação Visual e Numérica da Calibração do Modelo Hidrológico IPH II com Fins Educacionais. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, XVII, 2007, São Paulo. *Anais...* São Paulo: ABRH, 2007.
- BRIANEZI, T. R. *Aplicação do SMAP para a bacia do rio Tietê*. 2015. 85 f. Dissertação (Mestrado em Tecnologia e Inovação) – Faculdade de Tecnologia, Universidade Estadual de Campinas, Limeira, 2015.
- BRÖCKER, J.; SMITH, L. A. Increasing the Reliability of Reliability Diagrams. *Weather and Forecasting*, Vol. 22, Issue 3, p. 651-661, 2007. <https://doi.org/10.1175/WAF993.1>.
- BROWN, J. D.; DEMARGNE, J.; SEO, D-J.; LIU, Y. The Ensemble Verification System (EVS): A software tool for verifying ensemble forecasts of hydrometeorological and hydrologic

variables at discrete locations. *Environmental Modelling & Software*, Vol. 25, No. 7, p. 854-872, 2010.

BROWNING, K. A. Quantitative Precipitation Forecasting. *Weather*, Volume 58, Issue 3, p. 126-127, 2003. doi:10.1256/wea.245.02.

BUIZZA, R.; HOUTEKAMER, P. L.; PELLERIN, G.; TOTH, Z.; ZHU, Y.; WEI, M. A Comparison of the ECMWF, MSC, and NCEP Global Ensemble Prediction Systems. *Monthly Weather Review*, Vol. 133, Issue 5, p. 1076-1097, 2005. <https://doi.org/10.1175/MWR2905.1>.

C3S - COPERNICUS CLIMATE CHANGE SERVICE. *Seasonal forecasts*. Disponível em: <<https://climate.copernicus.eu/seasonal-forecasts>>. Acesso em: março de 2021.

CANNON, A. J.; SOBIE, S. R.; MURDOCK, T. Q. Bias Correction of GCM Precipitation by Quantile Mapping: How Well Do Methods Preserve Changes in Quantiles and Extremes? *Journal of Climate*, Volume 28, Issue 17, p. 6938-6959, 2015. <https://doi.org/10.1175/JCLI-D-14-00754.1>

CASSARDO, C. The Role of Meteorological Models in the Prediction of Weather Hazards — the European Approach. In: JONES, J. A. A.; VARDANIAN, T. G.; HAKOPIAN, C. (Eds). *Threats to Global Water Security*. NATO Science for Peace and Security Programme. Dordrecht: Springer, 2009. p. 265-276. https://doi.org/10.1007/978-90-481-2344-5_30.

CAVALCANTI, I. F. A.; MARENGO, J. A.; SATYAMURTY, P.; NOBRE, C. A.; TROSNIKOV, I.; BONATTI, J. P.; MANZI, A. C.; TARASOVA, T.; PEZZI, L. P.; D'ALMEIDA, C.; SAMPAIO, G.; CASTRO, C. C.; SANCHES, M. B.; CAMARGO, H. Global Climatological Features in a Simulation Using the CPTEC-COLA AGCM. *Journal of Climate*, Vol. 15, No. 21, p. 2965-2988, 2002.

CDS - CLIMATE DATA STORE. *Datasets*. Disponível em: <<https://cds.climate.copernicus.eu/>>. Acesso em: outubro de 2020.

CEMADEN - CENTRO NACIONAL DE MONITORAMENTO E ALERTA DE DESASTRES NATURAIS. *Missão*. Disponível em: <<http://www2.cemaden.gov.br/missao-do-cemaden>>. Acesso em: junho de 2021.

CHO, H.; PARK, J.; KIM, D. Evaluation of Four GLUE Likelihood Measures and Behavior of Large Parameter Samples in ISPSO-GLUE for TOPMODEL. *Water*, Vol. 11, N. 447, 2019.

CLOKE, H. L.; PAPPENBERGER, F. Ensemble flood forecasting: A review. *Journal of Hydrology*, Vol. 375, n. 3-4, p. 613-626, 2009.

COLLIER, C. G., KZYZYSZTOFOWICZ, R. Quantitative Precipitation Forecasting. *Journal of Hydrology*, Vol. 239, Issues 1-4, p. 1-2, 2000. doi:10.1016/s0022-1694(00)00389-9.

COLLISCHONN, W. *Simulação Hidrológica de Grandes Bacias*. 2001. 277 f. Tese (Doutorado em Engenharia de Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.

COPERNICUS - EUROPE'S EYES ON EARTH. *Climate change*. Disponível em: <<https://www.copernicus.eu/en/copernicus-services/climate-change>>. Acesso em: março de 2021.

CPC/NOAA - CLIMATE PREDICTION CENTER / NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. *El Niño / Southern Oscillation (ENSO)*. Disponível em: <<https://www.cpc.ncep.noaa.gov/products/precip/CWlink/MJO/enso.shtml>>. Acesso em: março de 2021.

CRC-SAS – CENTRO REGIONAL DO CLIMA PARA O SUL DA AMÉRICA DO SUL. *Atlas Climático*. Disponível em: <https://www.crc-sas.org/pt/mapas_normales_todos_crc.php> Acesso em: março de 2021.

ECMWF - EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS. *SEAS5 user guide*. Version 1.1, November 2017.

EHR - DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E RECURSOS HÍDRICOS (UFMG). *Downloads*. Disponível em: < <http://www.ehr.ufmg.br/downloads/>>. Acesso em: fevereiro de 2020.

EPE - EMPRESA DE PESQUISA ENERGÉTICA (Brasil). *Balanço Energético Nacional 2020: Ano base 2019*. Empresa de Pesquisa Energética, Rio de Janeiro - RJ, 292 p, 2020.

FAN, F. M. *Previsão por conjunto de vazões afluentes a reservatórios em grandes bacias hidrográficas brasileiras*. 2015. 384 f. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

FAYAL, M. A. A. *Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet*. 2008. 158 f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

FERNANDES, W. S. *Método para a estimação de quantis de enchentes extremas com o emprego conjunto de análise Bayesiana, de informações não sistemáticas e de distribuições limitadas superiormente*. 2009. 185 f. Tese (Doutorado em Saneamento, Meio Ambiente e Recursos Hídricos) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

FERNANDES, W.; NAGHETINNI, M., LOSCHI, R. A Bayesian approach for estimating extreme flood probabilities with upper-bounded distribution functions. *Stochastic Environmental Research and Risk Assessment*, n. 24, p. 1127-1143, 2010.

FLATO, G., MAROTZKE, J.; ABIODUN, B.; BRACONNOT, P.; CHOU, S.C.; COLLINS, W.; COX, P.; DRIQUECH, F.; EMORI, S.; EYRING, V.; FOREST, C.; GLECKLER, P.; GUILYARDI, E.; JAKOB, C.; KATTSOV, V.; REASON C.; RUMMUKAINEN, M. Evaluation of Climate Models. In: STOCKER, T. F.; QIN, D.; PLATTNER, G. -K.; TIGNOR, M.; ALLEN, S. K.; BOSCHUNG, J.; NAUELS, A.; XIA, Y.; BEX, V.; MIDGLEY, P. M. (Eds.) *Climate Change 2013: The Physical Science Basis*. United Kingdom and New York: Cambridge University Press, Chapter 9, 2013, p. 741-866.

GALVÃO, C. O. *Aplicabilidade em recursos hídricos da previsão de precipitação de longo prazo no nordeste do Brasil*. 1999. 151 f. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1999.

GOLDING, B.; MYLNE, K.; CLARK, P. The history and future of numerical weather prediction in the Met Office. *Weather*, Volume 59, Issue 11, p. 299-306, 2006.

HOUSER, P. R.; LANNOY, G. J. M.; WALKER, J. P. Hydrologic Data Assimilation. In: TIEFENBACHER, J. (Ed). *Approaches to Managing Disaster – Assessing Hazards, Emergencies and Disaster Impacts*. Texas: IntechOpen, 2012. 176 p.

INMET - INSTITUTO NACIONAL DE METEOROLOGIA. *Clima*. Disponível em: <<https://clima.inmet.gov.br/prec>>. Acesso em: abril de 2021.

INMET - INSTITUTO NACIONAL DE METEOROLOGIA. *SISDAGRO: Sistema de Suporte à Decisão na Agropecuária*. Disponível em: <<http://sisdagro.inmet.gov.br/sisdagro/app/index>>. Acesso em: fevereiro de 2020.

IVO, A. A. S.; BATISTA, C. L. G.; MATTIELLO-FRANCISCO, F. CEMADEN: A Study of Technological Vulnerabilities in a Natural Disaster Monitoring Network. *11º Workshoop em Engenharia e Tecnologias Espaciais*, 2020.

JACOBSON, M. Z. *Fundamentals of Atmospheric Modeling*. Second Edition. New York: Cambridge, 2005. 813 p.

JENSEN, J. B. Parameter and Uncertainty Estimation in Groundwater Modelling. Aalborg: *The Hydraulics and Coastal Engineering Group*, Dept. of Civil Engineering, Aalborg University. Series paper, No. 23, 2003.

JOHNSON, S. J.; STOCKDALE, T. N.; FERRANTI, L.; BALMASEDA, M. A.; MOLTENI, F.; MAGNUSSON, L.; TIETSCHKE, S.; DECREMER, D.; WEISHEIMER, A.; BALSAMO, G.; KEELEY, S. P. E.; MOGENSEN, K.; ZUO, H.; MONGE-SANZ, B. M. SEAS5: the new ECMWF seasonal forecast system. *Geoscientific Model Development*, Volume 12, Issue 3, p. 1087-1117, 2019. <https://doi.org/10.5194/gmd-12-1087-2019>.

JIN, X.; XU, C.; ZHANG, Q.; SINGH, V. P. Parameter and modeling uncertainty simulated by GLUE and a formal Bayesian method for a conceptual hydrological model. *Journal of Hydrology*, Volume 383, Issue 3-4, p. 147-155, 2010.

KALNAY, E. *Atmospheric Modeling, Data Assimilation, and Predictability*. New York: Cambridge University Press, 2003. 368 p.

KIMURA, R. Numerical weather prediction. *Journal of Wind Engineering and Industrial Aerodynamics*, Vol. 90, p. 1403-1414, 2002.

KIRTMAN, B. P.; MIN, D.; INFANTI, J. M.; KINTER III, J. L.; PAOLINO, D. A.; ZHANG, Q.; DOOL, H. V. D.; SAHA, S.; MENDEZ, M. P.; BECKER, E.; PENG, P.; TRIPP, P.; HUANG, J.; DEWITT, D. G.; TIPPETT, M. K.; BARNSTON, A. G.; LI, S.; ROSATI, A.; SCHUBERT, S. D.; RIENECKER, M.; SUAREZ, M.; LI, Z. E.; MARSHAK, J.; LIM, Y.-K.; TRIBBIA, J.; PEGION, K.; MERRYFIELD, W. J.; DENIS, B.; WOOD, E. F. The North American Multimodel Ensemble: Phase-1 Seasonal-to-Interannual Prediction; Phase-2 toward Developing Intraseasonal Prediction. *Bulletin of the American Meteorological Society*, Volume 95, Issue 4, p. 585-601, 2014. doi:10.1175/BAMS-D-12-00050.1.

KRZYSZTOFOWICZ, R. The Case for Probabilistic Forecasting in Hydrology. *Journal of Hydrology*, Volume 249, Issue 1-4, p. 2-9, 2001.

LETTENMAIER, D. P.; WOOD, E. F. Hydrologic Forecasting. In: MAIDMENT, D. R. *Handbook of Hydrology*. McGRAW-HILL, 1993. Chapter 26.

LI, H.; LUO, L.; WOOD, E. F. Seasonal hydrologic predictions of low-flow conditions over eastern USA during the 2007 drought. *Atmospheric Science Letters*, Vol. 9, p. 61-66, 2008. doi:10.1002/asl.182.

LIU, Y.; WEERTS, A. H.; CLARK, M.; HENDRICKS FRANSSEN, H.-J.; KUMAR, S.; MORADKHANI, H.; SEO, D.-J.; SCHWANENBERG, D.; SMITH, P.; VAN DIJK, A. I. J. M.; VAN VELZEN, N.; HE, M.; LEE, H.; NOH, S. J.; RAKOVEC, O.; RESTREPO, P. Advancing data assimilation in operational hydrologic forecasting: progresses, challenges, and emerging opportunities. *Hydrology and Earth System Science*, Vol. 16, Issue 10, p. 3863-3887, 2012. <https://doi.org/10.5194/hess-16-3863-2012>.

- LOPES, J. E. G. *Manual do Modelo SMAP*. 1999.
- LOPES, J. E. G.; BRAGA JÚNIOR, B. P. F.; CONEJO, J. G. L. Simulação Hidrológica: Aplicação de um Modelo Simplificado. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, III, 1981, Fortaleza. *Anais...* Fortaleza: ABRH, 1981.
- LORENZ, E. N. Deterministic Nonperiodic Flow. *Journal of the Atmospheric Sciences*, Volume 20, Issue 2, p. 130-141, 1963. [https://doi.org/10.1175/1520-0469\(1963\)020<0130:DNF>2.0.CO;2](https://doi.org/10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2).
- MALDONADO, L. H.; KAZAY, D. F.; LOPEZ, E. E. R. The estimation of the uncertainty associated with rating curves of the river Ivinhema in the state of Paraná/Brazil. *E3S Web Conf*, Volume 40, 2018. <https://doi.org/10.1051/e3sconf/20184006029>.
- MANTOVAN, P.; TODINI, E. Hydrological forecasting uncertainty assessment: Incoherence of the GLUE methodology. *Journal of Hydrology*, Volume 330, Issues 1-2, p. 368-381, 2006.
- MELLER, A. *Previsão de Cheias por Conjunto em Curto Prazo*. 2012. 204 f. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.
- MONTANARI, A. What do we mean by ‘uncertainty’? The need for a consistent wording about uncertainty assessment in hydrology. *Hydrological Processes*, Volume 21, Issue 6, p. 841-845, 2007. DOI: 10.1002/hyp.6623.
- MONTANARI, A. Uncertainty of Hydrological Predictions. In: PETER, W. (Ed.). *Treatise of Water Science*. Oxford: Elsevier, 2011. p. 459-478.
- NASEM - NATIONAL ACADEMIES OF SCIENCES, ENGINEERING, AND MEDICINE. *Next Generation Earth System Prediction: Strategies for Subseasonal to Seasonal forecasts*. Washington, D.C.: The National Academy Press, 2016. 350 p. <https://doi.org/10.17226/21873>.
- NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I – A discussion of principles. *Journal of Hydrology*, Volume 10, Issue 3, p. 282-290, 1970.
- NETO, A. A. M. *Ponderação bayesiana de modelos utilizando diferentes séries de precipitação aplicada à simulação chuva-vazão na Bacia do Ribeirão da Onça*. 2013. 110 f. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.
- NOAA - NATIONAL CENTERS FOR ENVIRONMENTAL INFORMATION. *Numerical Weather Prediction*, 2021a. Disponível em: <<https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/numerical-weather-prediction>>. Acesso em: janeiro de 2021.
- NOAA - NATIONAL CENTERS FOR ENVIRONMENTAL INFORMATION. *The History of Numerical Weather Prediction. 200 Years of Science, Service and Stewardship*, 2021b. Disponível em: <https://celebrating200years.noaa.gov/foundations/numerical_wx_pred/welcome.html>. Acesso em: fevereiro de 2021.
- NOAA CLIMATE.GOV. *Global impacts of El Niño and La Niña*. Disponível em: <<https://www.climate.gov/news-features/featured-images/global-impacts-el-niño-and-la-niña>>. Acesso em: março de 2021.
- NWS/NOAA - NATIONAL WEATHER SERVICE / NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. *Advanced Hydrologic Prediction Service: Probability Information*, 2021a. Disponível em:

<https://water.weather.gov/ahps2/probability_information.php?wfo=mfr&gage=apro3>.

Acesso em: março de 2021.

NWS/NOAA - NATIONAL WEATHER SERVICE / NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. *River Forecast Centers*, 2021b. Disponível em: <<https://water.weather.gov/ahps/rfc/rfc.php>>. Acesso em: junho de 2021.

ONS - OPERADOR NACIONAL DO SISTEMA. *Generalização do Modelo SMAP/ONS para Previsão de Vazões no Âmbito do SIN*. Nota Técnica 0056-2018, Revisão 2, 2018, 35 p.

ONS - OPERADOR NACIONAL DO SISTEMA. *Procedimentos de Rede - Submódulo 4.6: Análise e tratamento dos dados hidroenergéticos e previsão e geração de cenários de vazões*. Revisão 2020.12 – Procedimental, 2020a, 7 p.

ONS - OPERADOR NACIONAL DO SISTEMA. *Relatório Anual de Avaliação das Previsões de Vazões e Energias Naturais Afluentes de 2019*. Relatório DPL-REL-0173/2020 R0, 2020b, 107 p.

ONS - OPERADOR NACIONAL DO SISTEMA. *Sobre o ONS: o que é ONS*, 2020c. Disponível em: <<http://www.ons.org.br/>>. Acesso em: novembro de 2020.

PALMER, T. N.; ALESSANDRI, A.; ANDERSEN, U.; CANTELAUBE, P.; DAVEY, M.; DELECLUSE, P.; DEQUE, M.; DÍEZ, E.; DOBLAS-REYES, F. J.; FEDDERSEN, H.; GRAHAM, R.; GUALDI, S.; GUEREMY, J.-F.; HAGEDORN, R.; HOSHEN, M.; KEENLYSIDE, N.; LATIF, M.; LAZAR, A.; MAISONNAVE, E.; MARLETTO, V.; MORSE, A. P.; ORFILA, B.; ROGEL, P.; TERRES, J.-M.; THOMSON, M. C. Development of a European multimodel ensemble system for seasonal-to-interannual prediction (DEMETER). *Bulletin of the American Meteorological Society*, Volume 85, Issue 6, p. 853-872, 2004. doi:10.1175/BAMS-85-6-853.

PU, Z., KALNAY, E. Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation. In: DUAN, Q., PAPPENBERGER, F., THIELEN, J., WOOD, A., CLOKE, H., SCHAAKE, J. (Eds). *Handbook of Hydrometeorological Ensemble Forecasting*. Berlin: Springer, 2019. https://doi.org/10.1007/978-3-642-39925-1_11.

QUEDI, E. S. *Previsão Hidrológica em Horizonte Sub Sazonal*. 2019. 93 f. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

RASMUSSEN, E. M., DICKINSON, R. E., KUTZBACH, J. E., CLEAVELAND, M. K. Climatology. In: MAIDMENT, D. R. *Handbook of Hydrology*. McGRAW-HILL, 1993. Chapter 2.

RENNÓ, C. D.; SOARES, J. V. Modelos Hidrológicos para Gestão Ambiental. *Relatório Técnico Parcial*. Programa de Ciência e Tecnologia para Gestão de Ecossistemas, Ação “Métodos, modelos e geoinformação para a gestão ambiental”. Brasília: MCTI, INPE, 2000.

ROJAS, R.; FEYEN, L.; DASSARGUES, A. Conceptual model uncertainty in groundwater modeling: Combining generalized likelihood uncertainty estimation and Bayesian model averaging. *Water Resources Research*, Volume 44, W12418, 2008. <https://doi.org/10.1029/2008WR006908>.

ROUNDY, J.; DUAN, Q.; SCHAAKE, J. Hydrological Predictability, Scales, and Uncertainty Issues. In: DUAN, Q., PAPPENBER, F., WOOD, A., CLOKE, H., SCHAAKE, J. (Eds.). *Handbook of Hydrometeorological Ensemble Forecasting*. Berlin: Springer, 2019. https://doi.org/10.1007/978-3-642-40457-3_8-1.

SAHA, S.; MOORTHY, S.; WU, X.; WANG, J.; NADIGA, S.; TRIPP, P.; BEHRINGER, D.; HOU, Y-T.; CHUANG, H-Y.; IREDELL, M.; EK, M.; MENG, J.; YANG, R.; MENDEZ, M. P.; DOOL, H. V. D.; ZHANG, Q.; WANG, W.; CHEN, M.; BECKER, E. The NCEP Climate Forecast System Version 2. *Journal of Climate*, Volume 27, Issue 6, p. 2185-2208, 2014. <https://doi.org/10.1175/JCLI-D-12-00823.1>.

SARAIVA, I. S. *Regionalização de Parâmetros de Modelos de Simulação Hidrológica para Emprego em Bacias Hidrográficas sem Monitoramento Fluviométrico*. 2010. 124 f. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

SCHAAKE, J. C.; HAMILL, T. M.; BUIZZA, R.; CLARK, M. HEPEX The Hydrological Ensemble Prediction Experiment. *Bulletin American Meteorological Society*, Volume 88, Issue 10, p. 1541-1547, 2007. <https://doi.org/10.1175/BAMS-88-10-1541>.

SCHOUPS, G.; VRUGT, J. A formal likelihood function for parameter and predictive inference of hydrologic models with correlated, heteroscedastic, and non-Gaussian errors. *Water Resources Research*, Volume 46, W10531, 2010. doi:10.1029/2009WR008933.

SENE, K. *Hydrometeorology: Forecasting and Applications*. United Kingdom: Springer, 1st Edition, 2010, 366 p.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). *Biometrika*, Volume 52, Issue 3-4, p. 591-611, 1965. doi:10.1093/biomet/52.3-4.591.

SHRESTHA, D. L. *Uncertainty analysis in rainfall-runoff modelling: Application of machine learning techniques*. 2009. 205 f. Tese (Doutorado em Hidroinformática) – UNESCO-IHE Institute for Water Education, Delft University of Technology, Netherlands, 2009.

SILVA, B. C.; TUCCI, C. E. M.; COLLISCHON, W. Previsão de Vazão com Modelos Hidroclimáticos. *Revista Brasileira de Recursos Hídricos*, Volume 11, n. 3, p. 15-29, 2006.

SILVA, F. E. O. *Assimilação do padrão de variabilidade das variáveis de estado de um modelo chuva-vazão em esquemas de simulação/previsão hidrológica*. 2015. 211 f. Tese (Doutorado em Saneamento, Meio Ambiente e Recursos Hídricos) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2015.

SILVA, F. E.; NAGHETTINI, M., FERNANDES, W. Avaliação bayesiana das incertezas nas estimativas dos parâmetros de um modelo chuva-vazão conceitual. *Revista Brasileira de Recursos Hídricos*, Volume 19, n. 4, p. 148-159, 2014.

SITTERSON, J., KNIGHTES, C.; PARMAR, R.; WOLFE, K.; MUCHE, M.; AVANT, B. An Overview of Rainfall-Runoff Model Types. *U.S. Environmental Protection Agency (EPA), Office of Research and Development*. Washington - DC, 29 p, 2017.

SMITH, P. J.; PAPPENBERGER, F.; WETTERHALL, F.; THIELEN DEL POZO, J.; KRZEMINSKI, B.; SALAMON, P.; MURARO, D.; KALAS, M.; BAUGH, C. On the Operational Implementation of the European Flood Awareness System (EFAS). In: ADAMS, T. E.; PAGANO, T. C. (Eds.). *Flood Forecasting: A Global Perspective*. Academic Press: Cambridge, MA, USA, 2016. <http://dx.doi.org/10.1016/B978-0-12-801884-2.00011-6>.

SMITH, T.; SHARMA, A.; MARSHALL, L.; MEHROTRA, R.; SISSON, S. Development of a formal likelihood function for improved Bayesian inference of ephemeral catchments. *Water Resources Research*, Vol. 46, W12551, 2010. doi:10.1029/2010WR009514.

- STANSKI, H. R.; WILSON, L. J.; BURROWS, W. R. Survey of common verification methods in meteorology. *World Weather Watch Technical Report*, No.8, WMO/TD No.358, World Meteorological Organisation, Geneva, 1989.
- STEDINGER, J. R.; VOGEL, R. M.; LEE, S. U., BATCHELDER, R. Appraisal of the generalized likelihood uncertainty estimation (GLUE) method. *Water Resources Research*, Volume 44, Issue 12, W00B06, 2008.
- TODINI, E. Hydrological Catchment Modelling: Past, Present and Future. *Hydrology and Earth System Sciences*, Volume 11, Issue 1, p. 468-482, 2007.
- TODINI, E. Rainfall-runoff modeling - Past, present and future. *Journal of Hydrology*, Volume 100, Issues 1-3, p. 341-352, 1988.
- TOLSON, B. A. *Automatic calibration, management and uncertainty analysis: phosphorus transport in the Cannonsville watershed*. PhD Dissertation – Faculty of Graduate School, Cornell University, Ithaca, EUA, 2005.
- TOLSON, B.A. SHOEMAKER C.A. Dynamically Dimensioned Search algorithm for computationally efficient watershed model calibration. *Water Resources Research*, Vol. 43, n.1, p.1-16, 2007.
- TROCCOLI, A.; HARRISON, M.; ANDERSON, D. L. T.; MASON, S. J. *Seasonal Climate: Forecasting and Managing Risk*. Dordrecht: Springer/NATO Science Series, 2008. 467 p.
- TRZASKA, S.; SCHNARR, E. A Review of Downscaling Methods for Climate Change Projections. African and Latin American Resilience to Climate Change (ARCC). *United States Agency International Development (USAID)*, Tetra Tech ARD, p.1-42, 2014. <https://doi.org/10.4236/ojog.2016.613098>
- TUCCI, C. E. M. *Modelos Hidrológicos*. Segunda Edição. Porto Alegre: ABRH, 2005. 678 p.
- TUCCI, C. E. M.; CLARKE, R. T.; COLLISCHONN, W.; DIAS, P. L. S.; OLIVEIRA, G. S. Long-term flow forecasts based on climate and hydrologic modeling: Uruguay River basin. *Water Resources Research*, Vol. 39, No. 7, p. SWC 3-1 - SWC 3-11, 2003. doi:10.1029/2003WR002074.
- TUCCI, C. E. M.; ORDONEZ, J. S.; SIMÕES, M. L. Modelo Matemático Precipitação-Vazão IPH II: Alguns Resultados. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, III, 1981, Fortaleza. *Anais...Fortaleza*: ABRH, 1981.
- VITART, F.; ROBERTSON, A. W. The sub-seasonal to seasonal prediction project (S2S) and the prediction of extreme events. In: *npj Climate and Atmospheric Science*, Vol. 1, Number 3, 2018. <https://doi.org/10.1038/s41612-018-0013-0>
- VITART, F.; ROBERTSON, A. W.; ANDERSON, D. L. T. Sub-seasonal to seasonal prediction project: bridging the gap between weather and climate. In: *WMO Bulletin*, Vol. 61(2), p.23-28, 2012.
- VRUGT, J. A.; BRAAK, C. J. F.; GUPTA, H. V.; ROBINSON, B. A. Equifinality of Formal (DREAM) and Informal (GLUE) Bayesian Approaches in Hydrologic Modeling? *Stochastic Environmental Research and Risk Assessment*, Volume 23, Issue 7, p. 1011-1026, 2008.
- VRUGT, J.; MASSOUD, E. Uncertainty Quantification of Complex System Models: Bayesian Analysis. In: DUAN, Q., PAPPENBER, F., WOOD, A., CLOKE, H., SCHAAKE, J. (Eds.). *Handbook of Hydrometeorological Ensemble Forecasting*. Berlin: Springer, 2019. https://doi.org/10.1007/978-3-642-40457-3_27-1.

WANG, Q. J.; ROBERTSON, D. E.; CHIEW, F. H. S. A Bayesian joint probability modeling approach for seasonal forecasting of streamflows at multiple sites. *Water Resources Research*, Vol. 45, W05407, 2009. doi:10.1029/2008WR007355.

WANG, Q. J.; SHAO, Y.; SONG, Y.; SCHEPEN, A.; ROBERTSON, D. E.; RYU, D.; PAPPENBERGER, F. An evaluation of ECMWF SEAS5 seasonal climate forecasts for Australia using a new forecast calibration algorithm. *Environmental Modelling & Software*, Volume 122, 2019. <https://doi.org/10.1016/j.envsoft.2019.104550>.

WILKS, D. S. *Statistical Methods in the Atmospheric Sciences*. Second Edition. ELSEVIER: Academic Press, 2006. 627 p.

WMO - WORLD METEOROLOGICAL ORGANIZATION. *Global Observing System (GOS)*. Disponível em: <<https://www.wmo.int/pages/prog/www/OSY/GOS.html>>. Acesso em: março de 2021.

WMO - WORLD METEOROLOGICAL ORGANIZATION. *Global Producing Centres for Long-Range Forecasts*. Disponível em: <<https://public.wmo.int/en/files/global-producing-centres-long-range-forecasts>>. Acesso em: dezembro de 2020.

WMO - WORLD METEOROLOGICAL ORGANIZATION. Precipitation estimation and forecasting. *Operational Hydrology Report*, No. 46, Geneva, 2000.

WMO - WORLD METEOROLOGICAL ORGANIZATION. Simulated real-time intercomparison of hydrological models. *Operational Hydrology Report*, No. 38, Geneva, 1992.

WOOD, A. W.; MAUER, E. P.; KUMAR, A.; LETTENMAIER, D. P. Long-range experimental hydrologic forecasting for the eastern United States. *Journal of Geophysical Research*, Vol. 107, No. D20, p.ACL 6-1 - ACL 6-15, 2002. doi:10.1029/2001JD000659.

XAVIER, L. N. R. *Análise da Incerteza Causada pela Representação da Precipitação no Modelo Topmodel*. 2002. 124 f. Dissertação (Mestrado em Ciências em Engenharia Civil) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2002.

XU, C.-Y. From GCMs to river flow: a review of downscaling methods and hydrologic. *Progress in Physical Geography*, Volume 23, No. 2, p. 229-249, 1999. doi: 10.1177/030913339902300204.

XUE, Y.; JANJIC, Z; DUDHIA, J; VASIC, R; DE SALES, F. A review on regional dynamical downscaling in intraseasonal to seasonal simulation/prediction and major factors that affect downscaling ability. *Atmospheric Research*, Volumes 147-148, p. 68-85, 2014. doi: 10.1016/j.atmosres.2014.05.001

YADAV, M.; WAGENER, T.; GUPTA, H. Regionalization of constraints on expected watershed response behavior for improved predictions in ungauged basins. *Advances in Water Resources*, Volume 30, Issue 8, p. 1756-1774, 2007.

YANG, J.; REICHERT, P.; ABBASPOUR, K. C.; XIA, J.; YANG, H. Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. *Journal of Hydrologic Engineering*, Volume 358, Issues 1-2, p. 1-23, 2008.

YUAN, X.; WOOD, E. F.; MA, Z. A review on climate-model-based seasonal hydrologic forecasting: physical understanding and system development. *WIREs Water*. Volume 2, Issue 5, p. 523-536, 2015. <https://doi.org/10.1002/wat2.1088>.

ZHANG, J.; CHEN, J.; LI X.; CHEN H.; XIE P.; LI W. Combining Postprocessed Ensemble Weather Forecasts and Multiple Hydrological Models for Ensemble Streamflow Predictions. *Journal of Hydrologic Engineering*, Volume 25, Issue 1, 2020.

ZHAO, T.; BENNETT, J.; WANG, Q. J.; SCHEPEN, A.; WOOD, A.; ROBERTSON, D.; RAMOS, M. H. How suitable is Quantile Mapping for post-processing GCM precipitation forecasts? *Journal of Climate*, Volume 30, Issue 9, p. 3185-3196, 2017. <https://doi.org/10.1175/JCLI-D-16-0652.1>.

**APÊNDICE A: ESP'S OBTIDOS PARA CADA SUB-BACIA MODELADA,
PARA AS DIFERENTES SÉRIES DE PRECIPITAÇÃO PREVISTA**

APÊNDICE A1: PRECIPITAÇÃO PREVISTA COM INÍCIO EM AGOSTO/2018

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

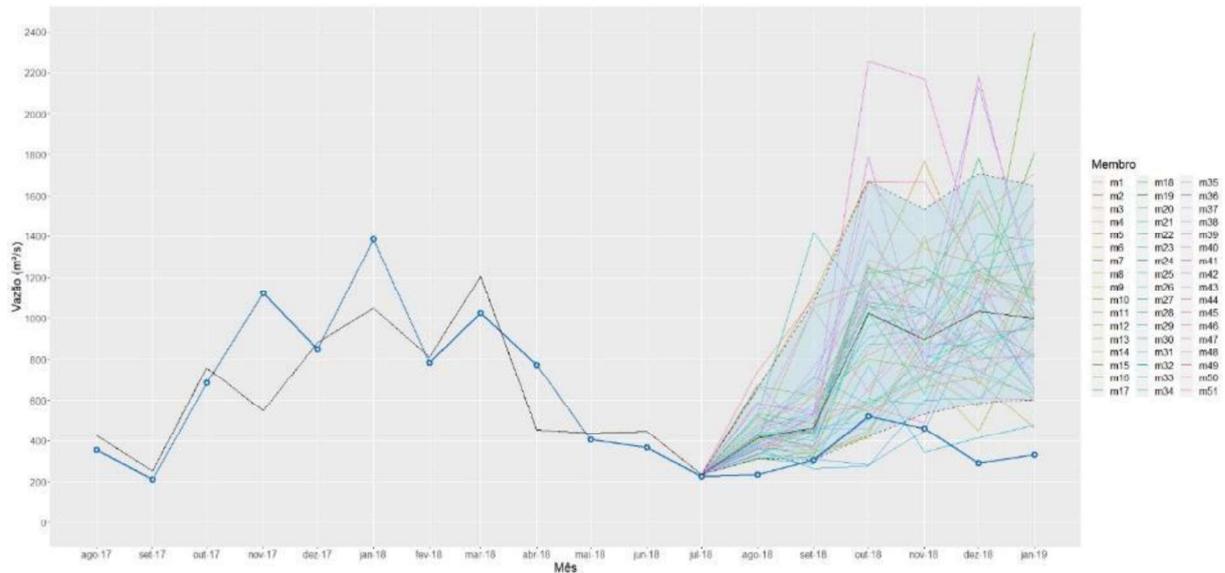


Figura AP.1 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em agosto/2018.

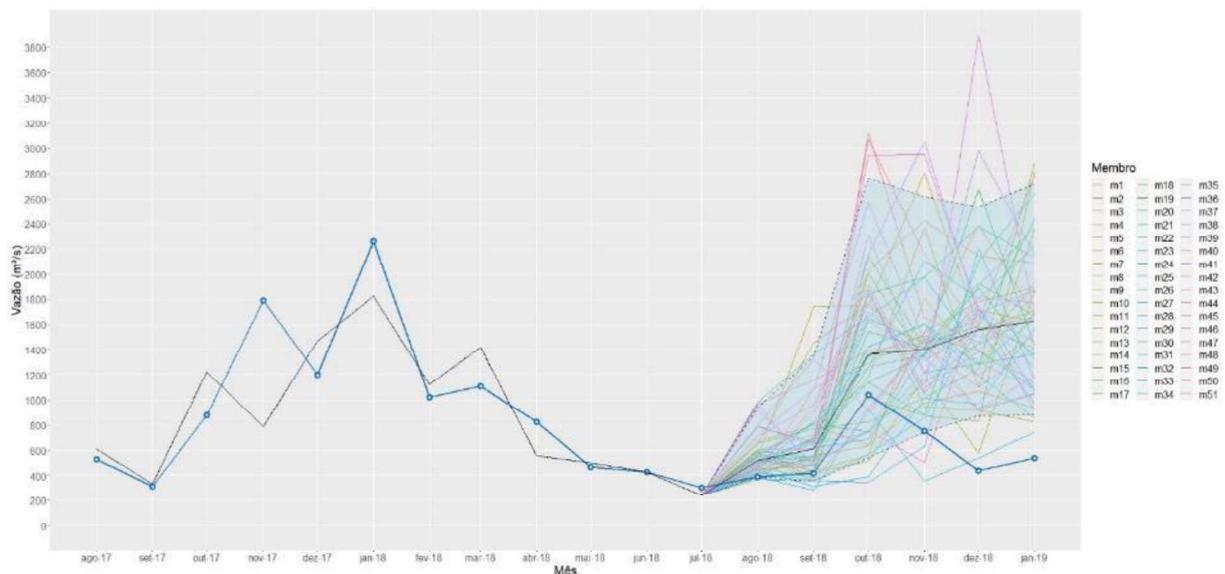


Figura AP.2 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em agosto/2018.

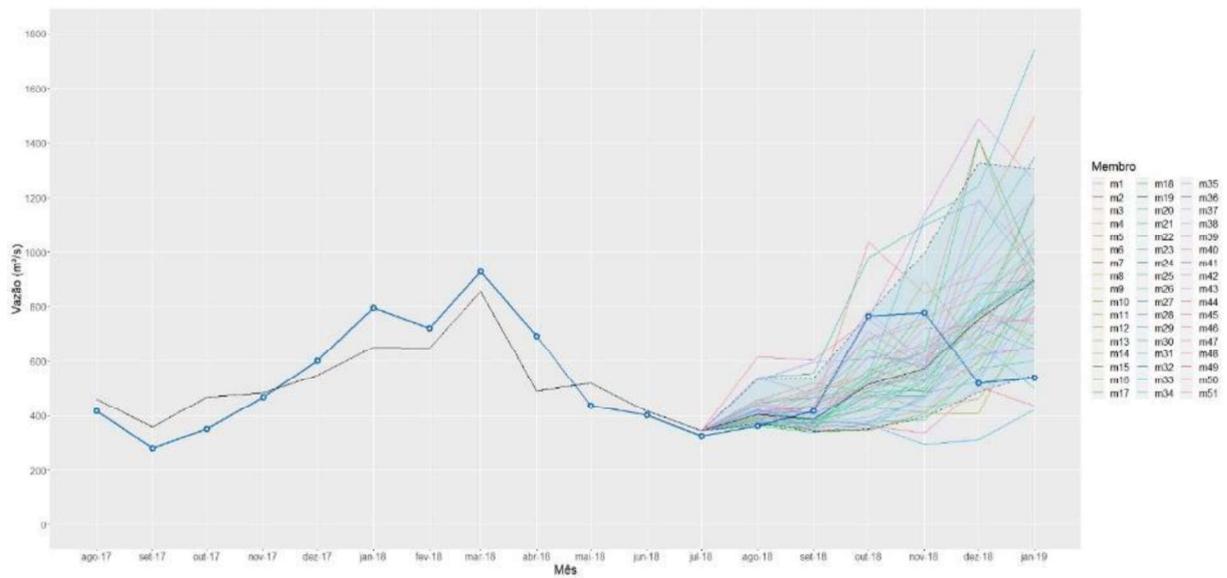


Figura AP.3 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em agosto/2018.

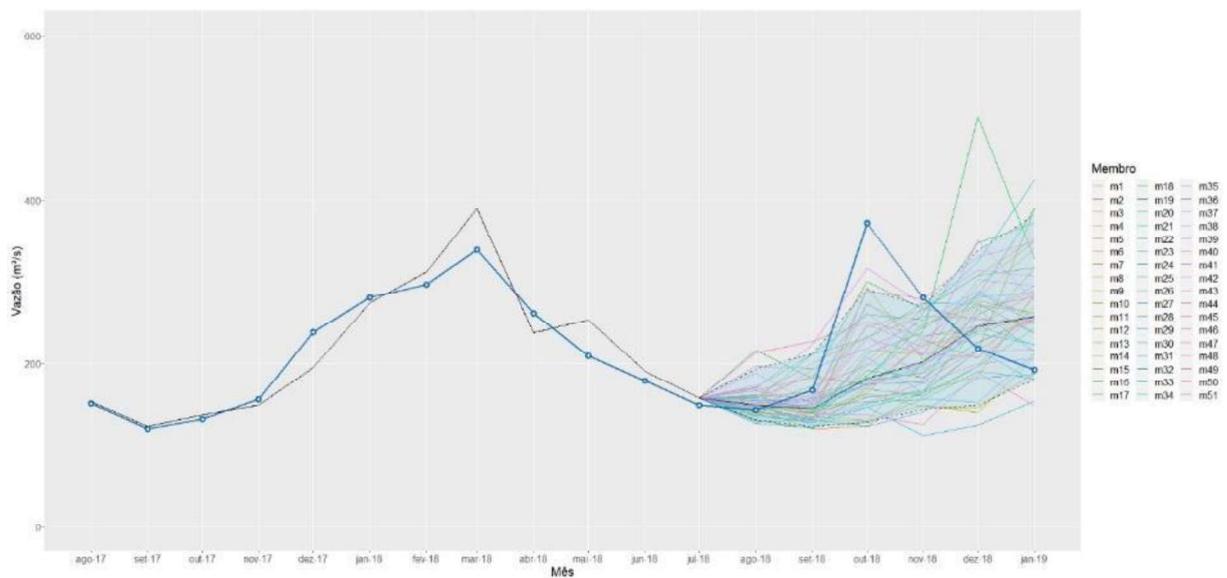


Figura AP.4 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em agosto/2018.

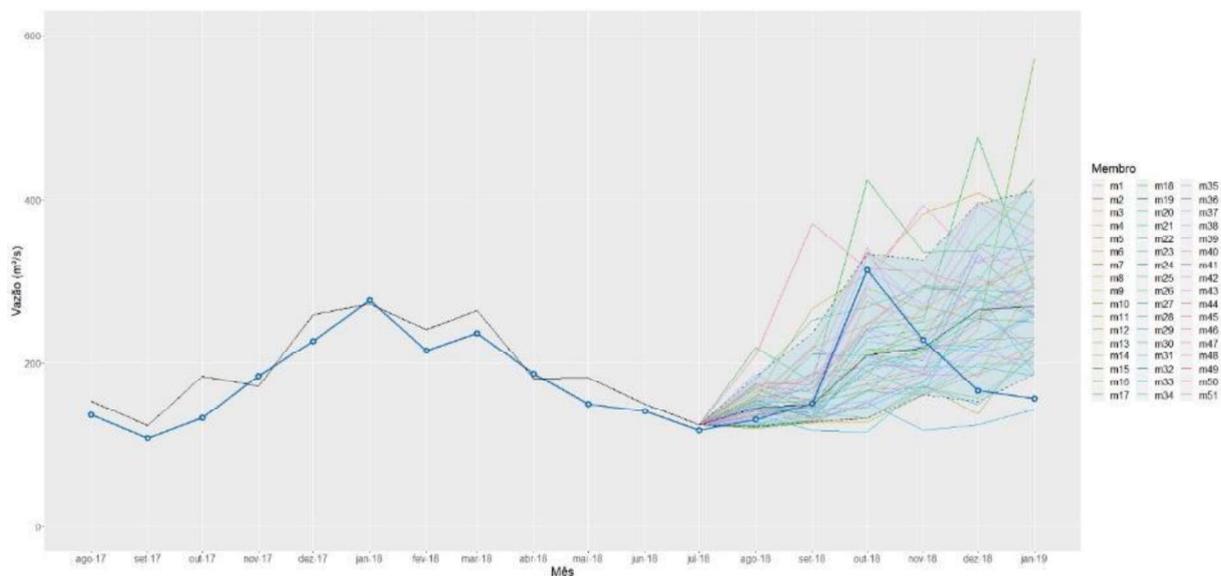


Figura AP.5 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em agosto/2018.

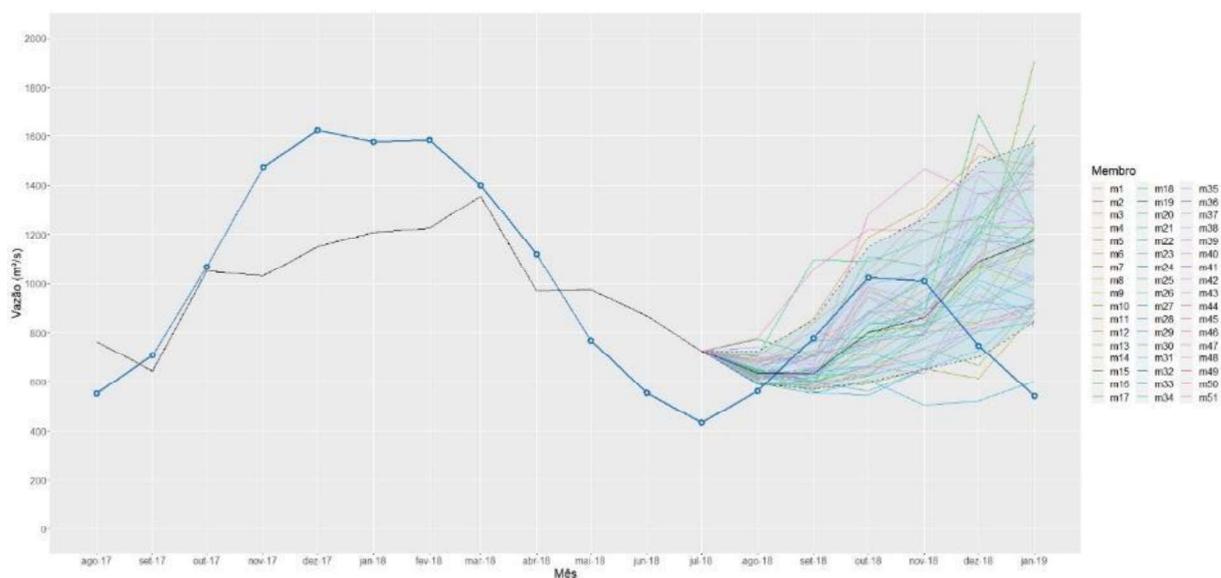


Figura AP.6 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em agosto/2018.

APÊNDICE A2: PRECIPITAÇÃO PREVISTA COM INÍCIO EM SETEMBRO/2018

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

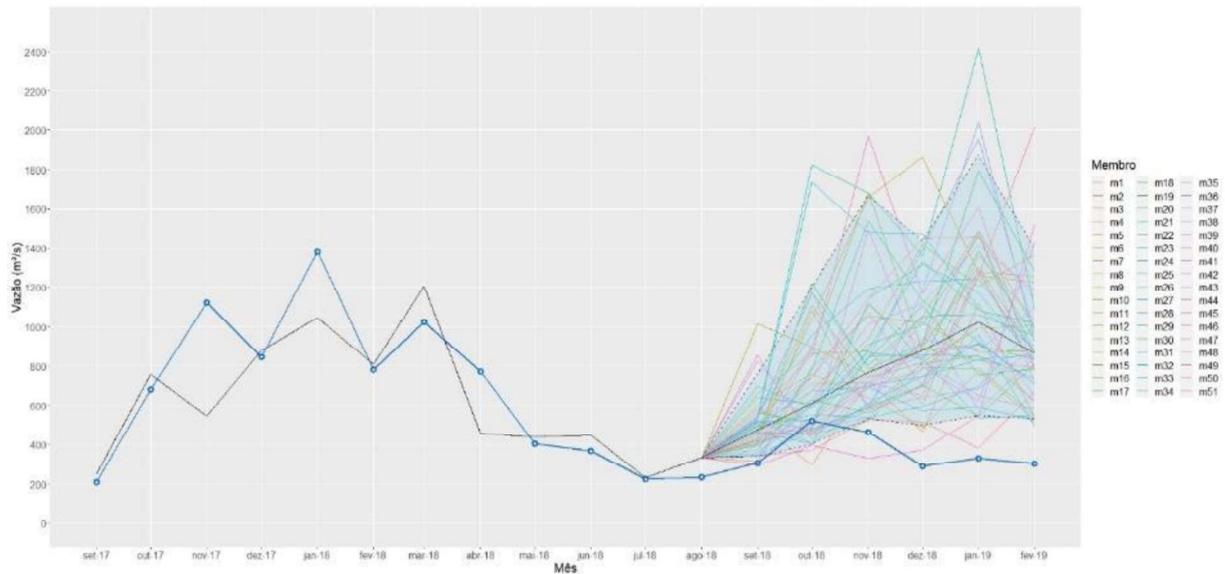


Figura AP.7 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em setembro/2018.

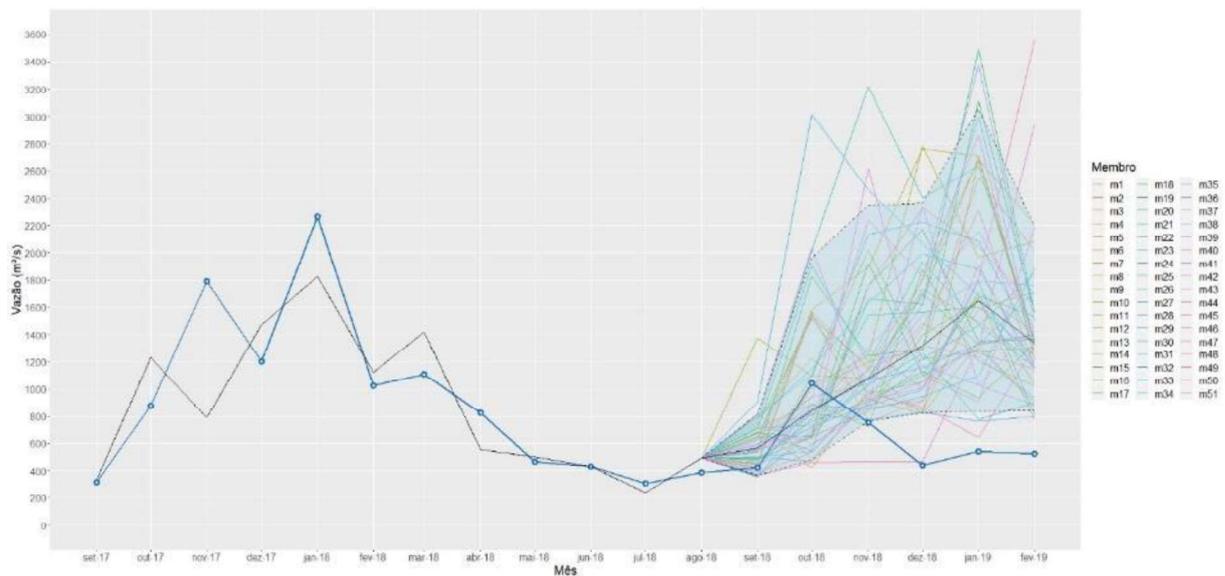


Figura AP.8 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em setembro/2018.

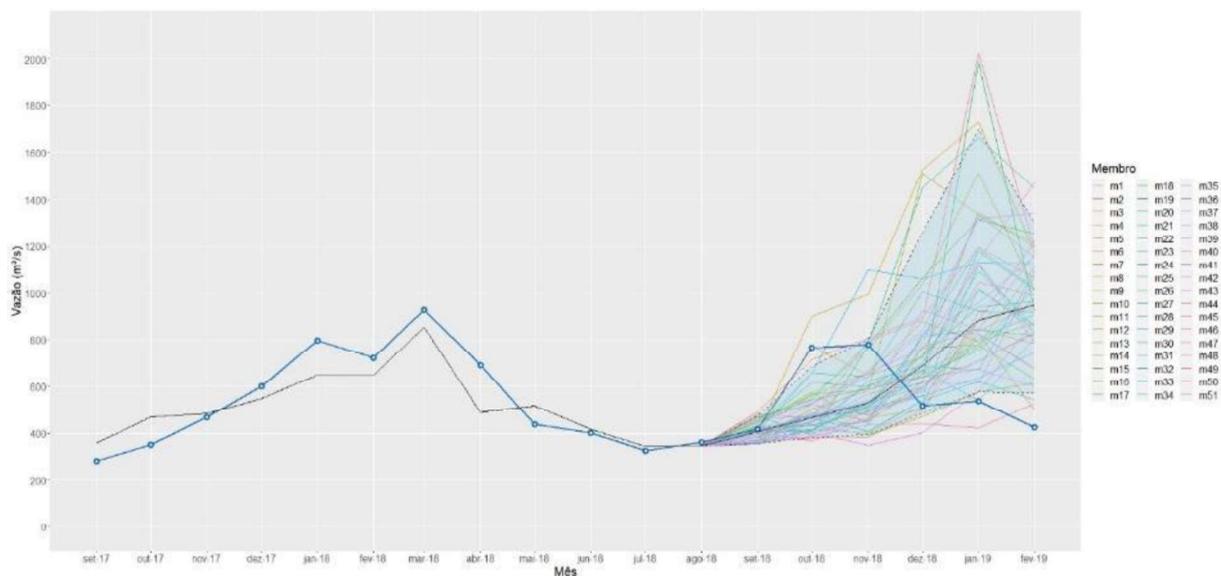


Figura AP.9 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em setembro/2018.

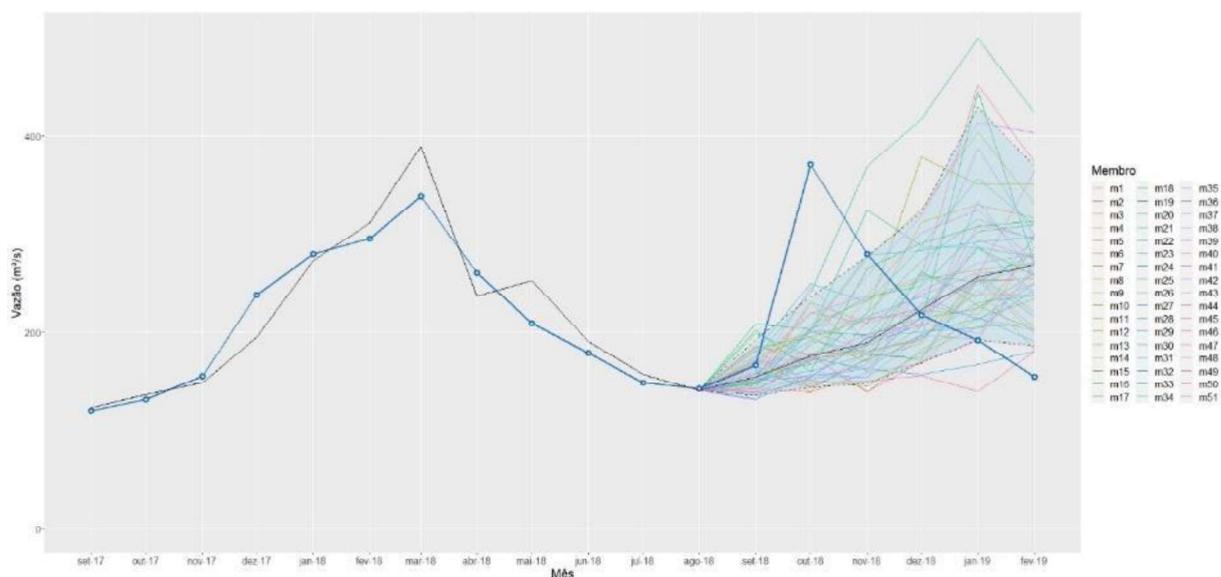


Figura AP.10 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em setembro/2018.

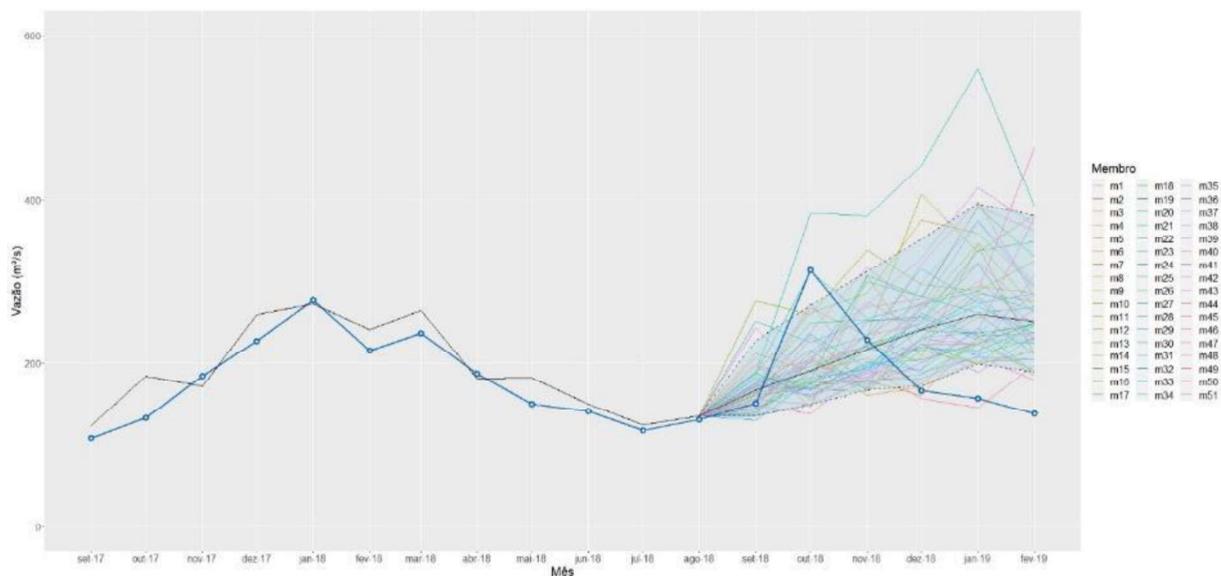


Figura AP.11 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em setembro/2018.

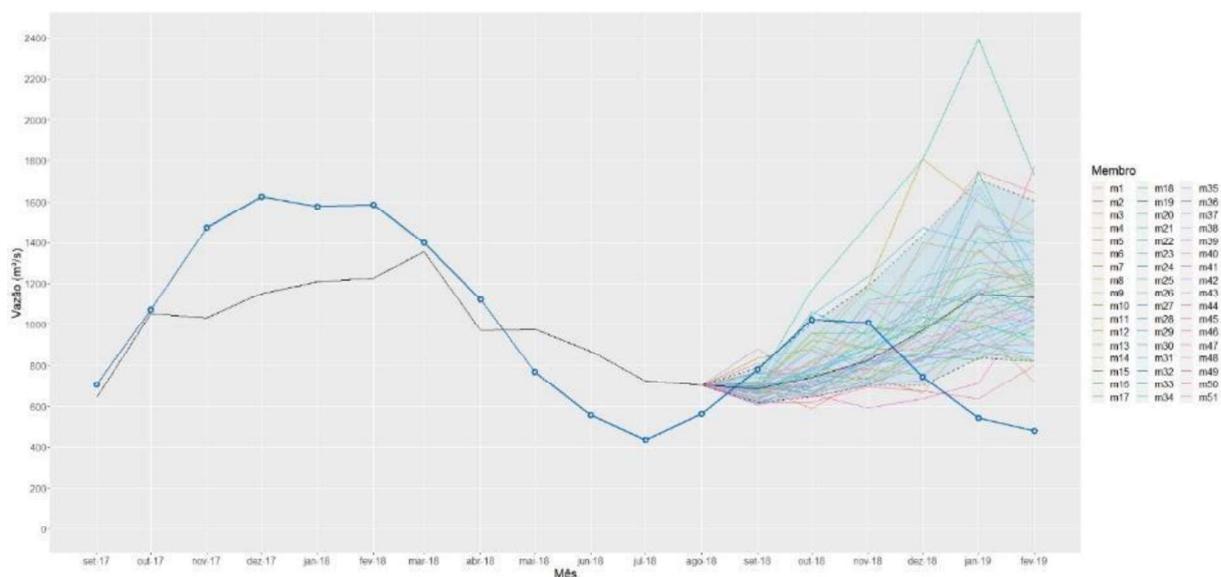


Figura AP.12 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em setembro/2018.

APÊNDICE A3: PRECIPITAÇÃO PREVISTA COM INÍCIO EM OUTUBRO/2018

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

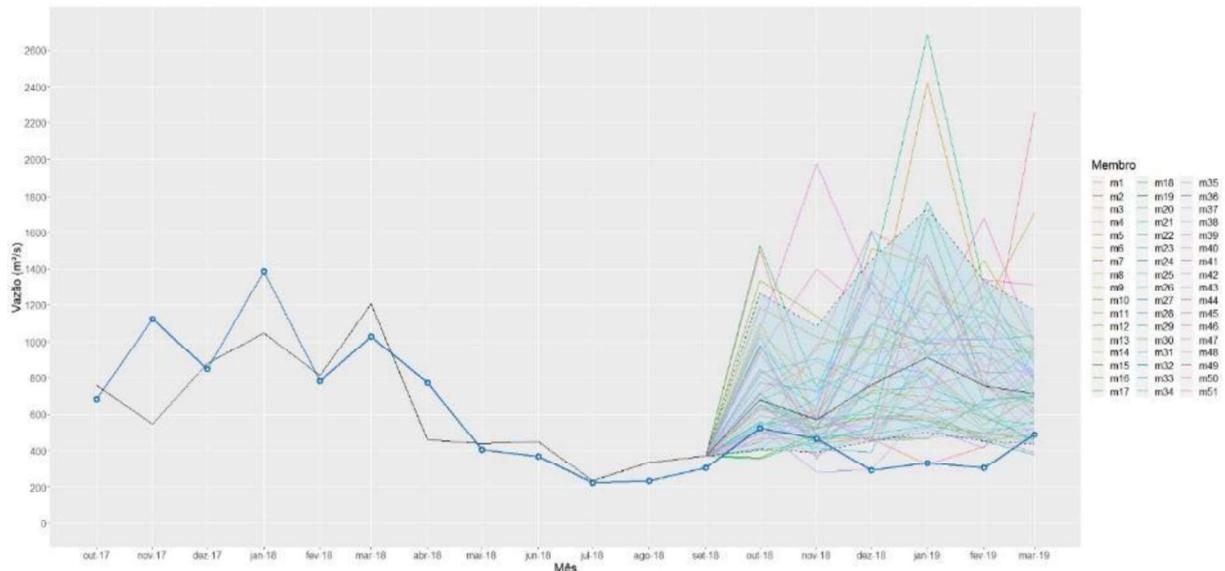


Figura AP.13 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em outubro/2018.

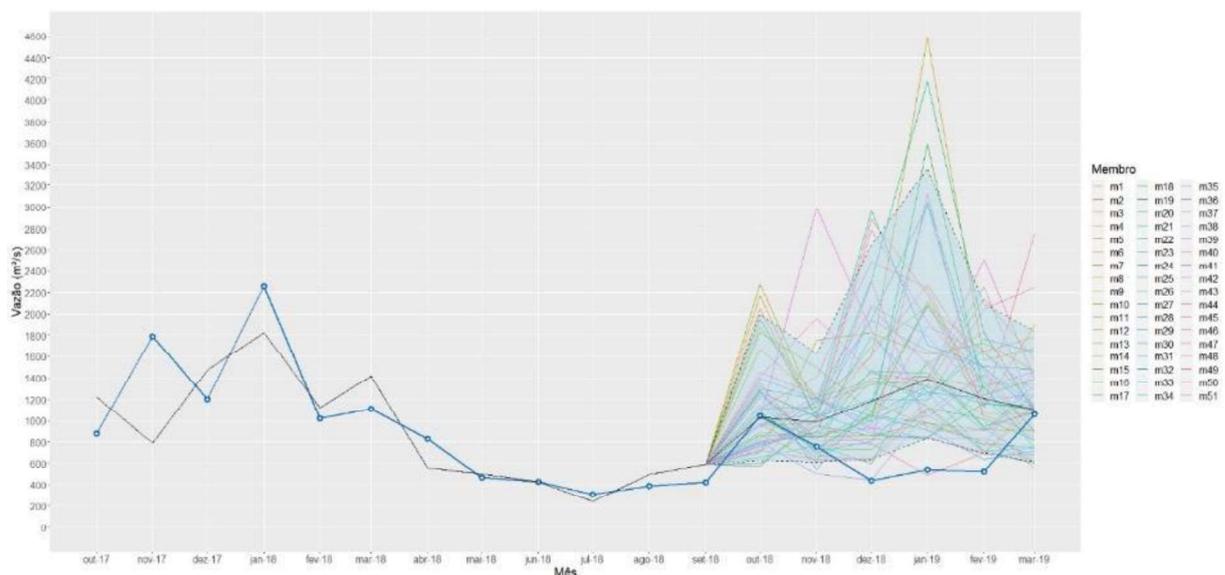


Figura AP.14 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em outubro/2018.

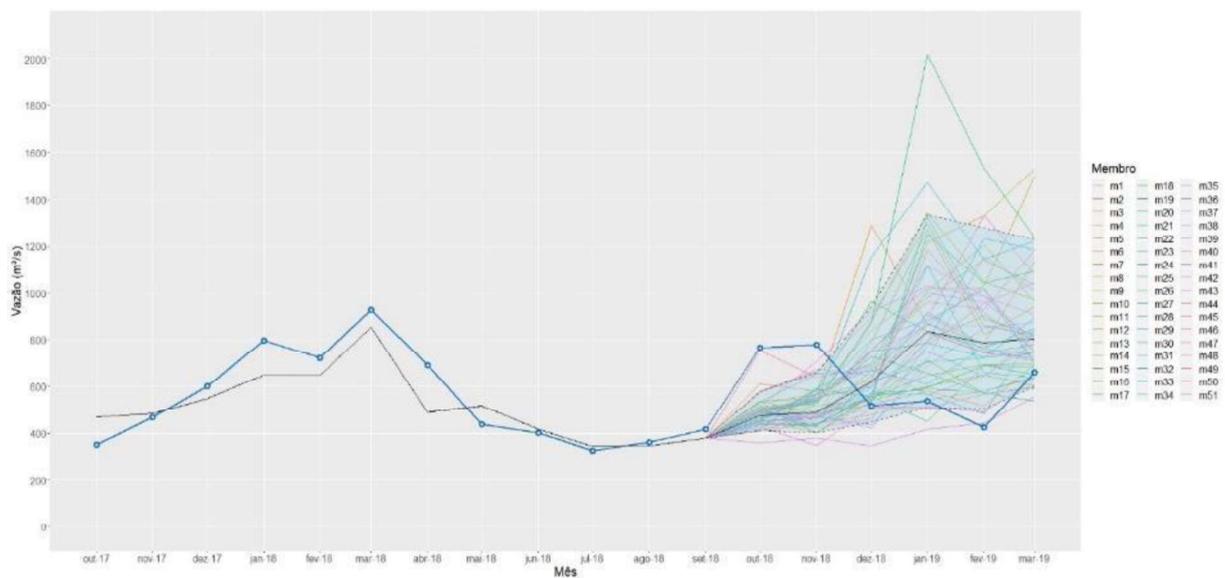


Figura AP.15 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em outubro/2018.

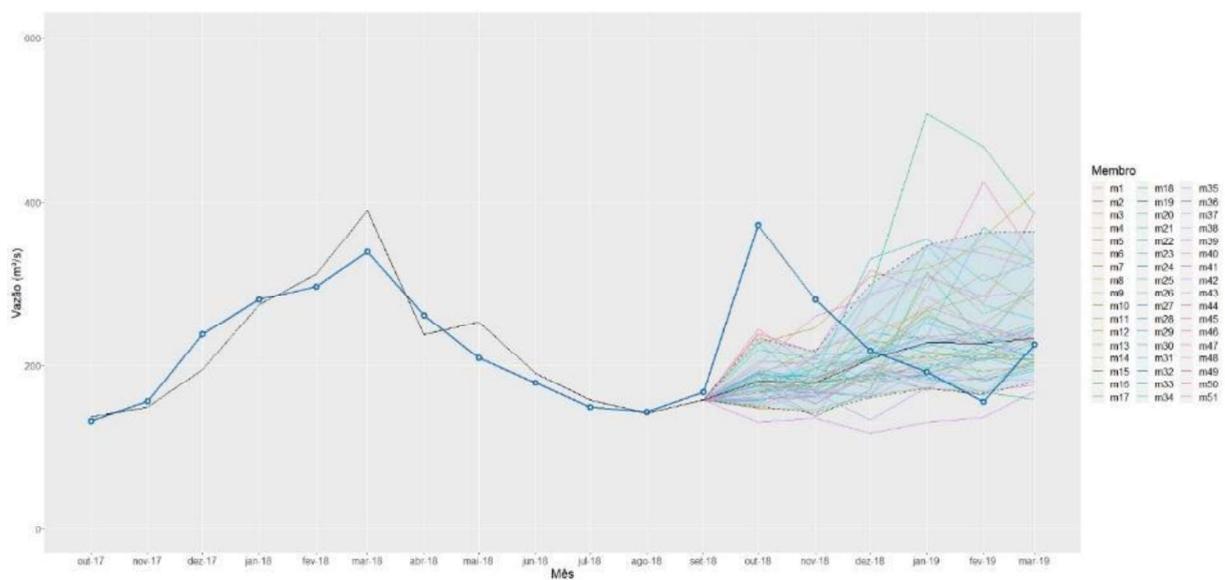


Figura AP.16 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em outubro/2018.

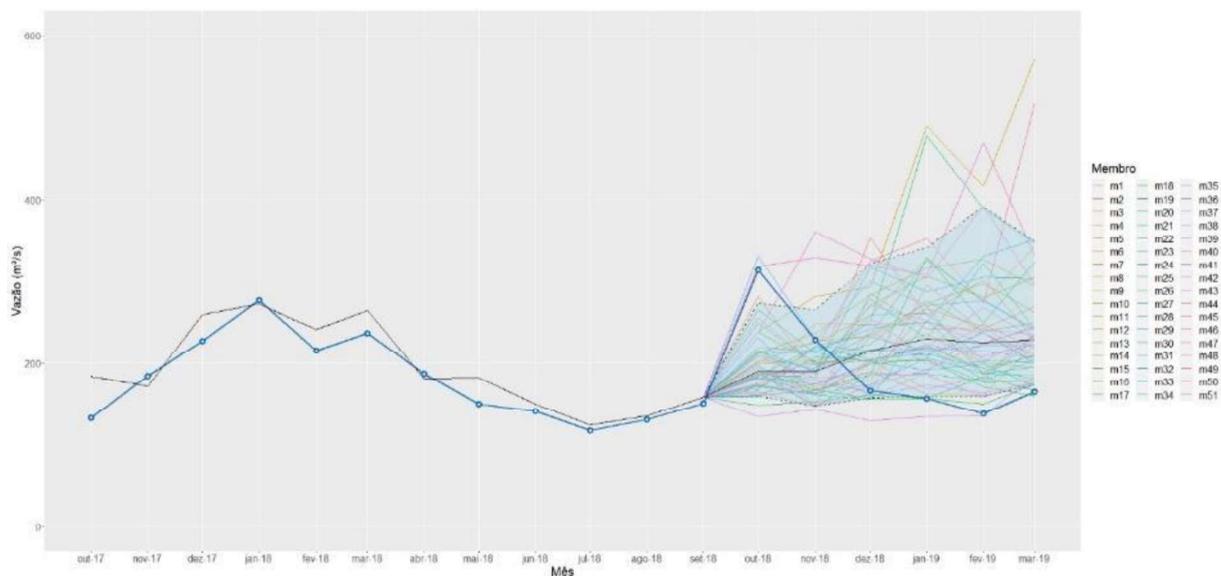


Figura AP.17 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em outubro/2018.

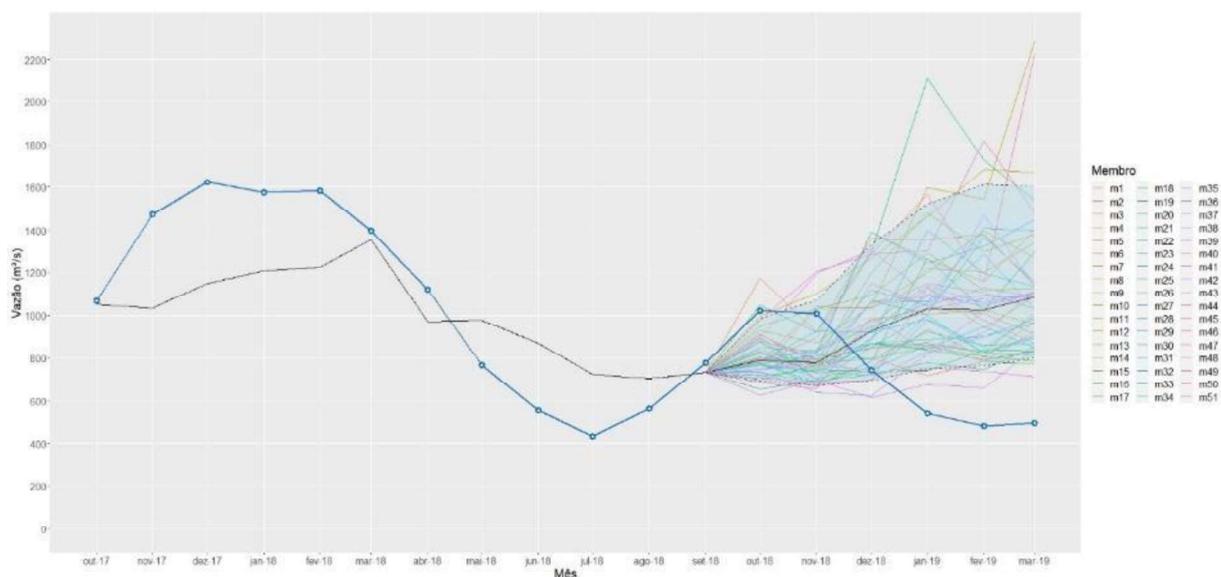


Figura AP.18 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em outubro/2018.

APÊNDICE A4: PRECIPITAÇÃO PREVISTA COM INÍCIO EM NOVEMBRO/2018

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

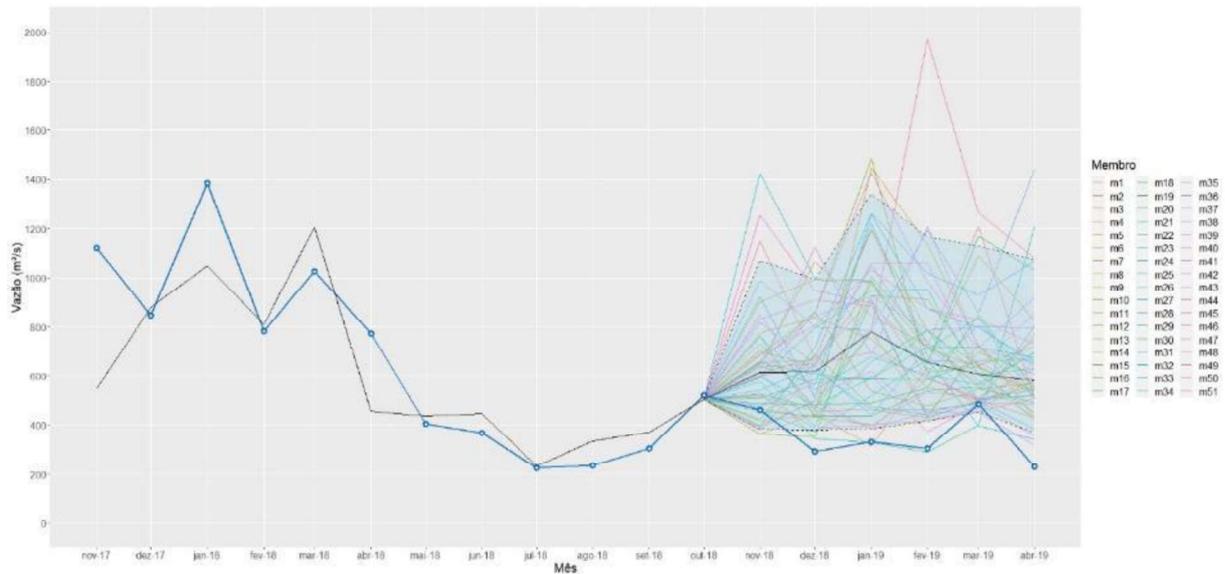


Figura AP.19 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em novembro/2018.

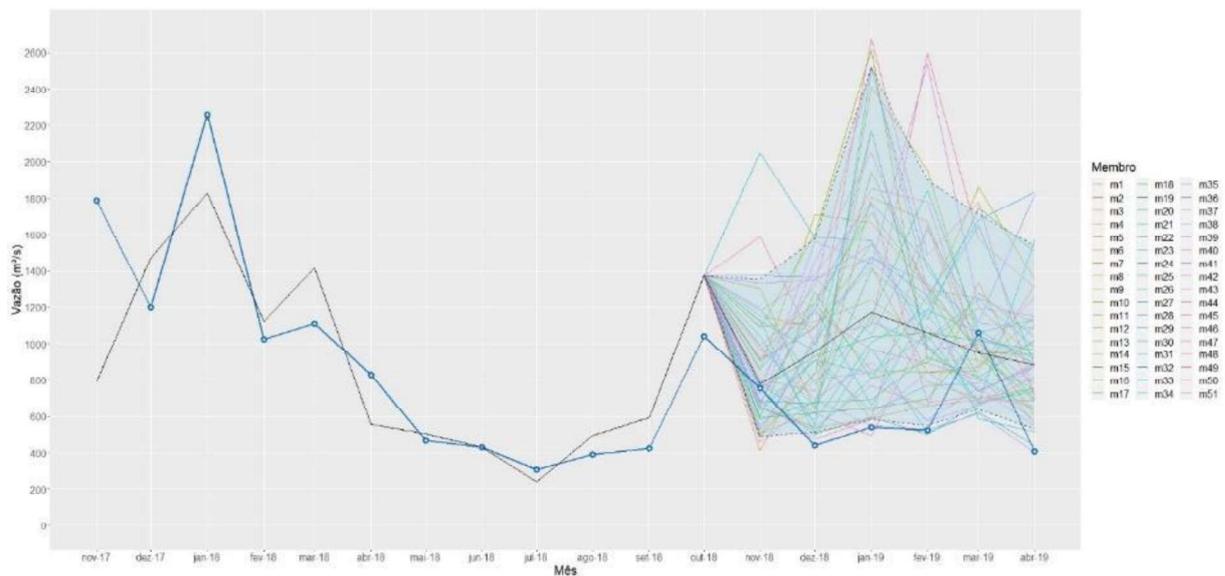


Figura AP.20 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em novembro/2018.

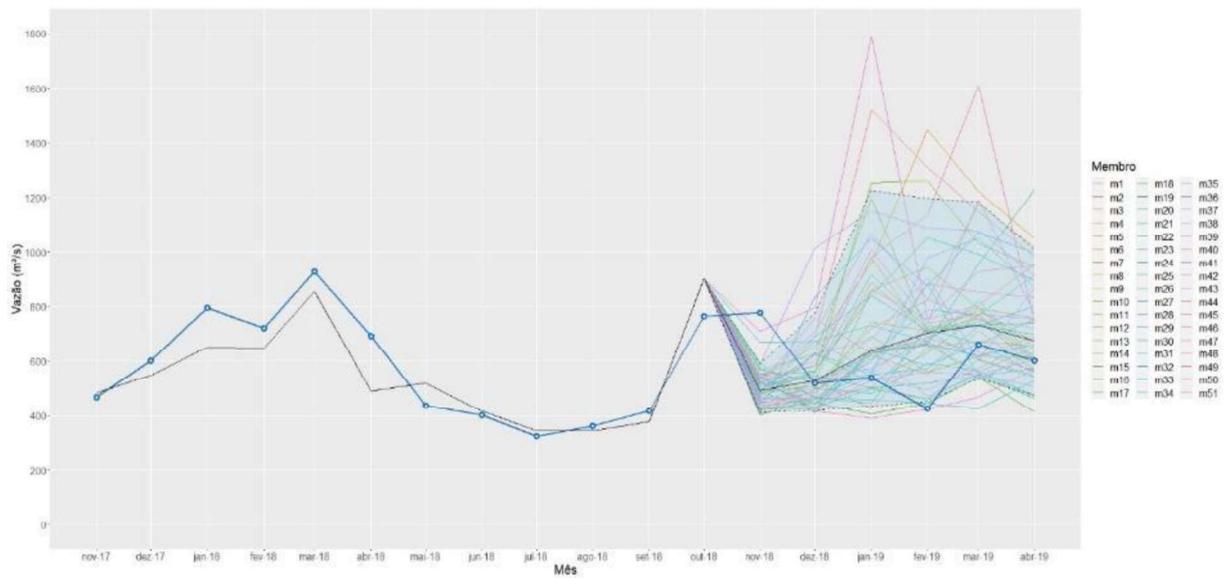


Figura AP.21 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em novembro/2018.

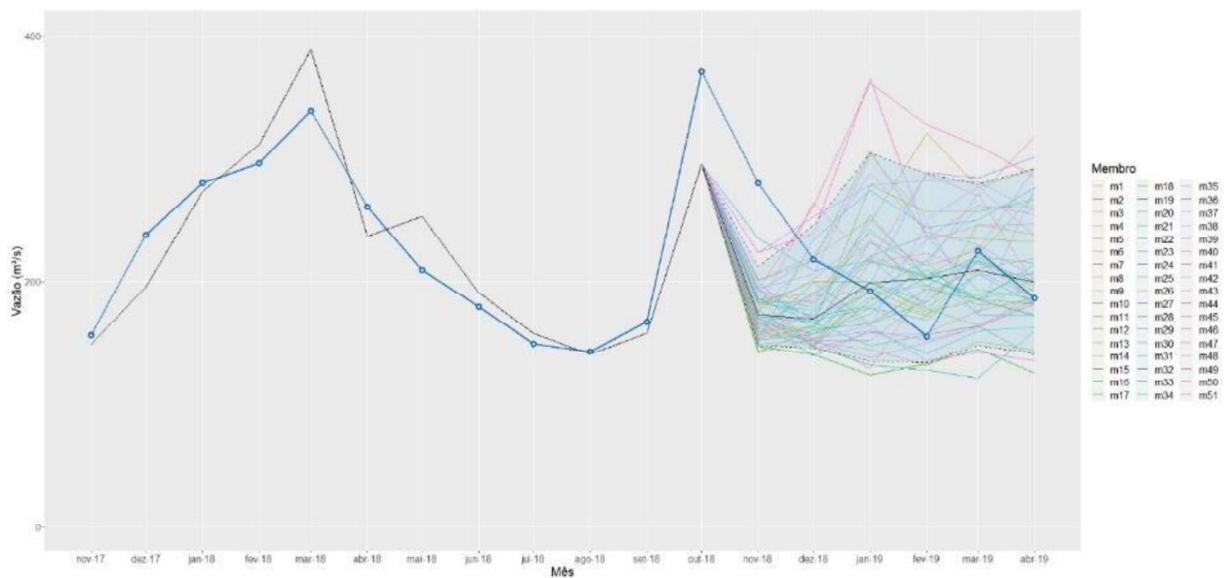


Figura AP.22 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em novembro/2018.

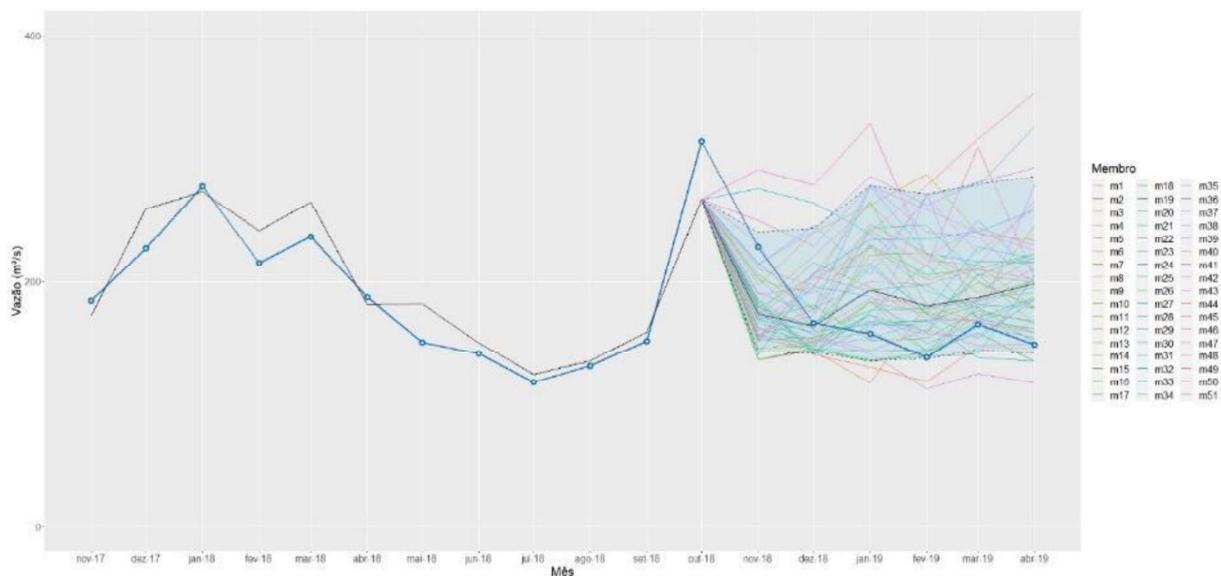


Figura AP.23 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em novembro/2018.

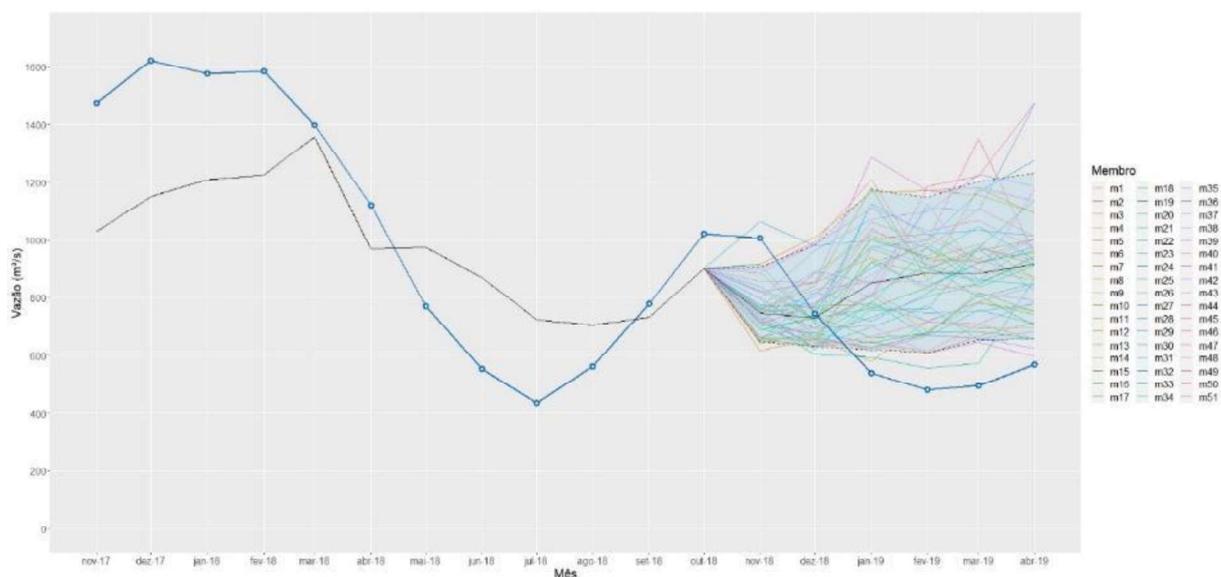


Figura AP.24 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em novembro/2018.

APÊNDICE A5: PRECIPITAÇÃO PREVISTA COM INÍCIO EM DEZEMBRO/2018

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

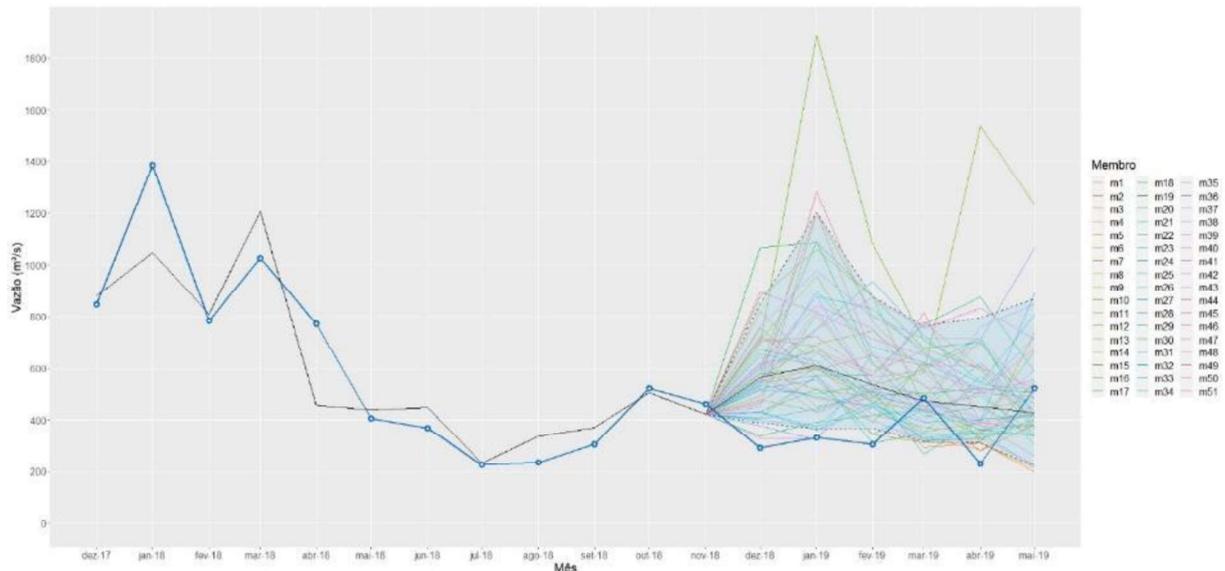


Figura AP.25 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em dezembro/2018.

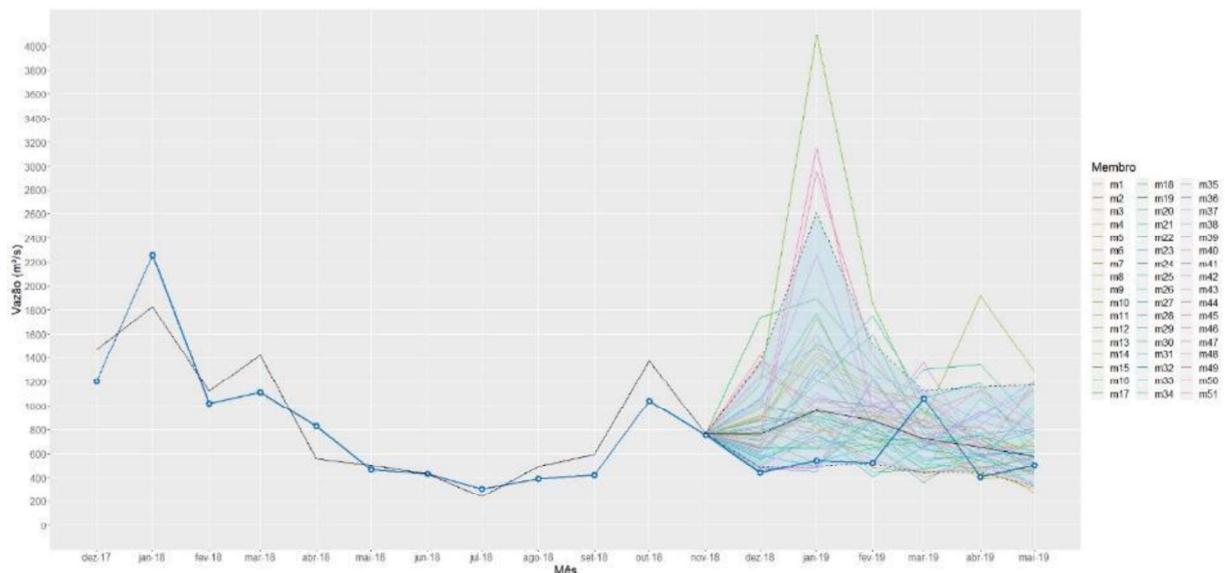


Figura AP.26 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em dezembro/2018.

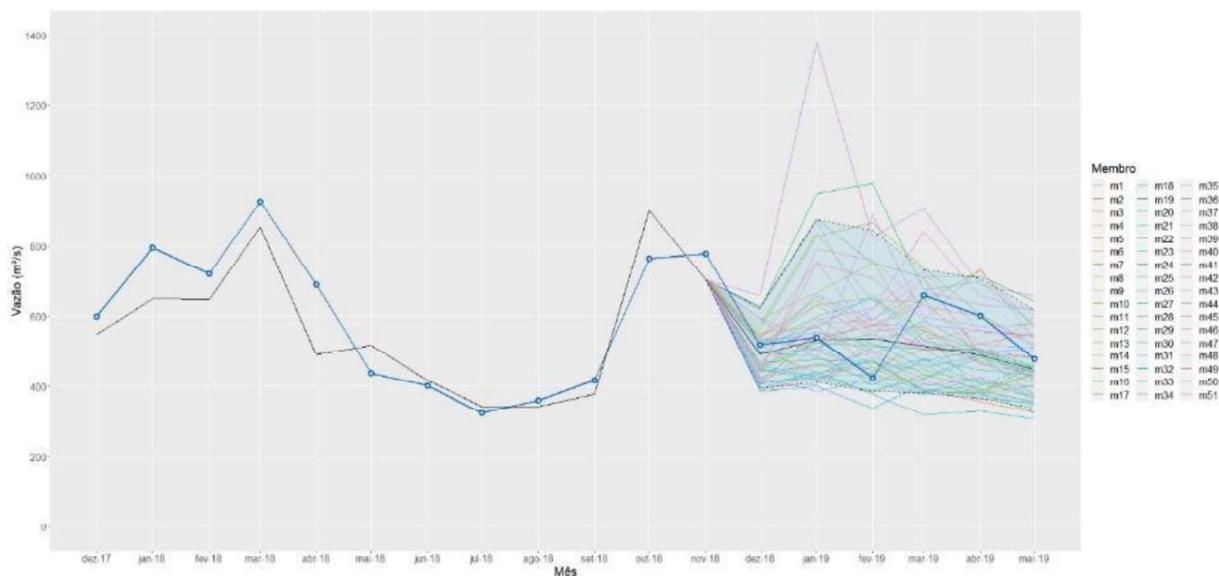


Figura AP.27 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em dezembro/2018.

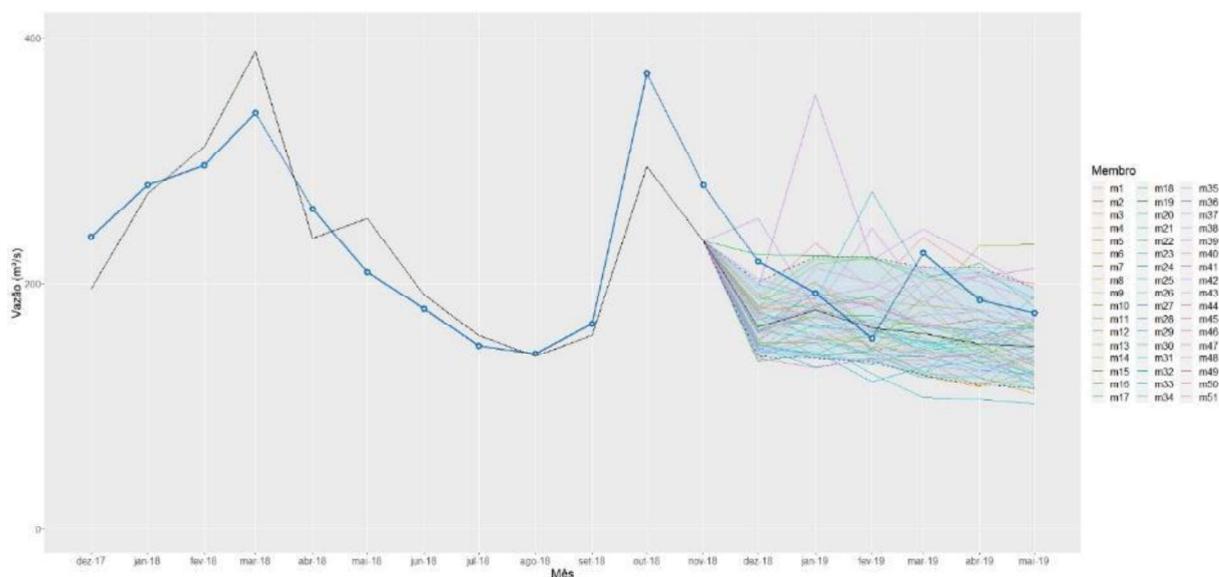


Figura AP.28 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em dezembro/2018.

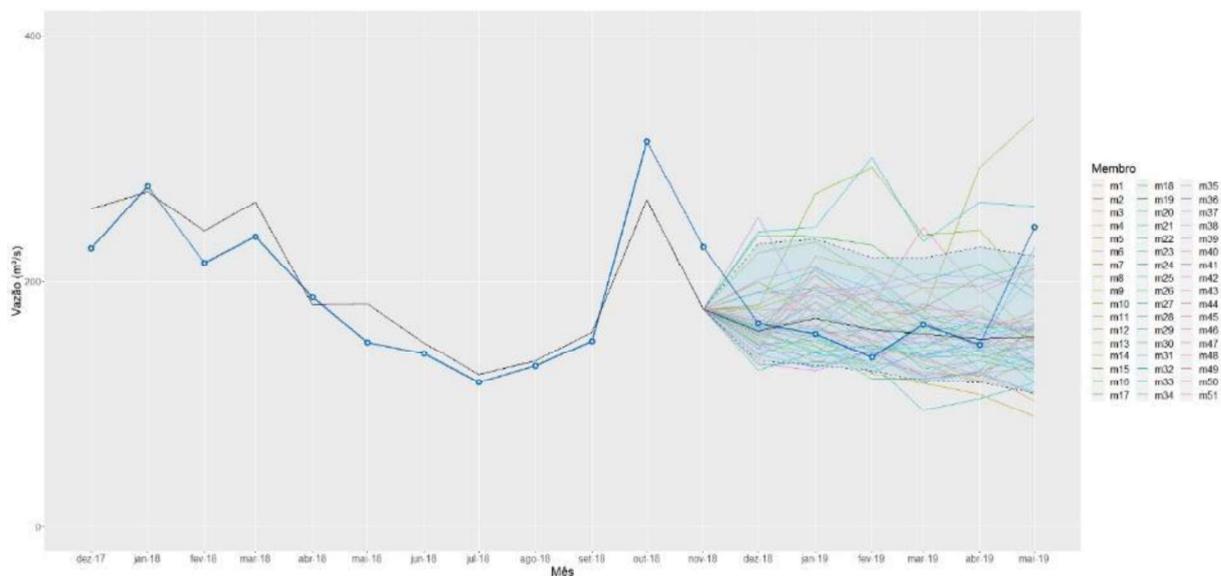


Figura AP.29 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em dezembro/2018.

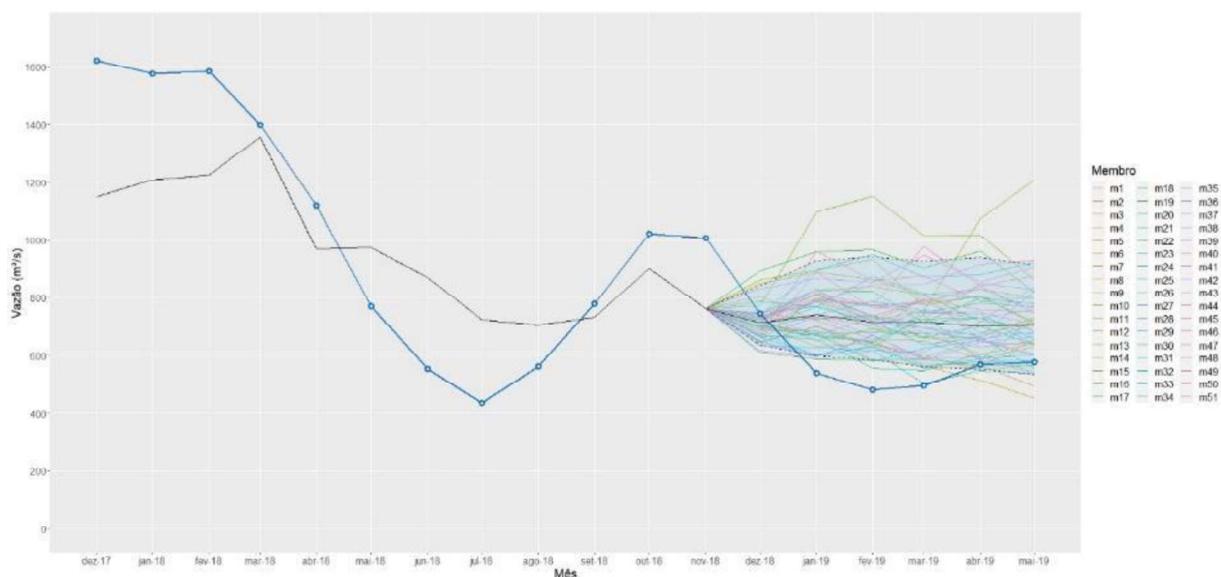


Figura AP.30 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em dezembro/2018.

APÊNDICE A6: PRECIPITAÇÃO PREVISTA COM INÍCIO EM JANEIRO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

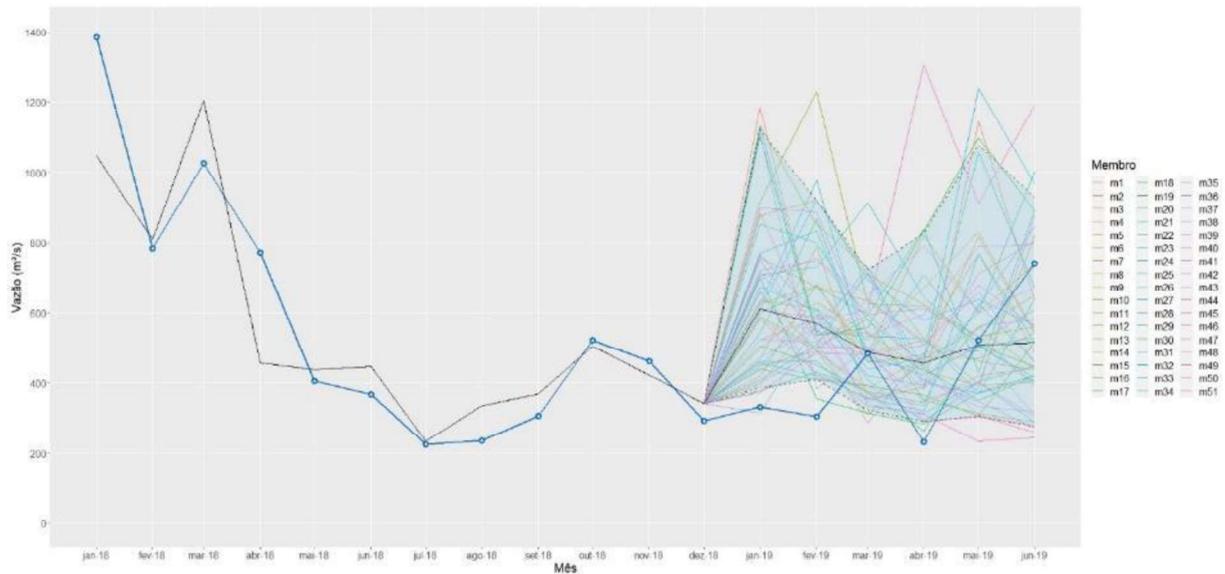


Figura AP.31 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em janeiro/2019.

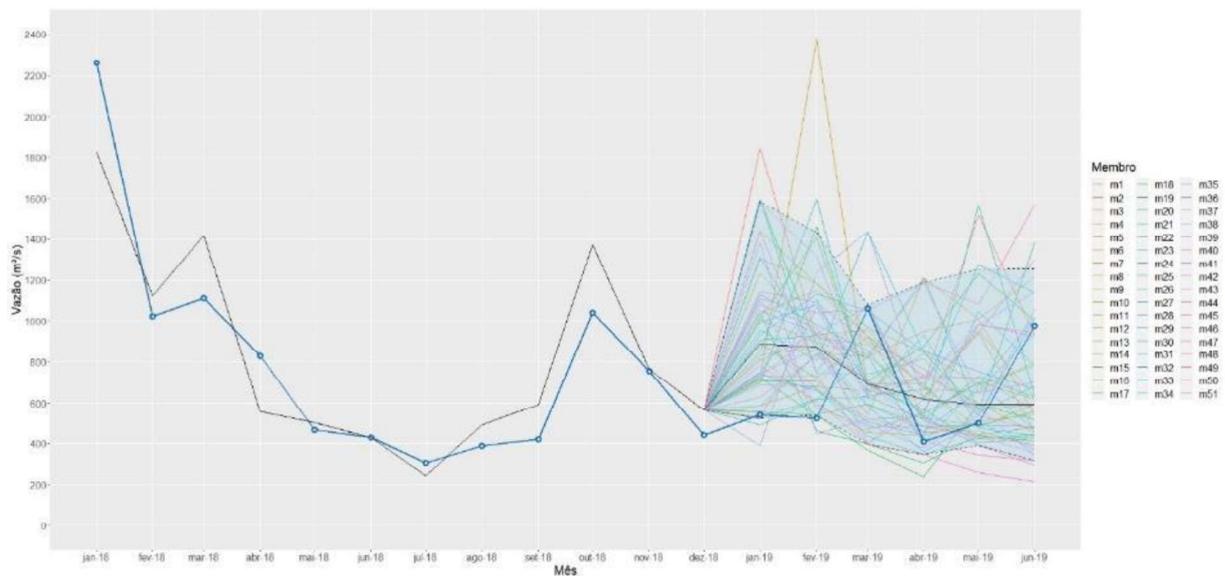


Figura AP.32 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em janeiro/2019.

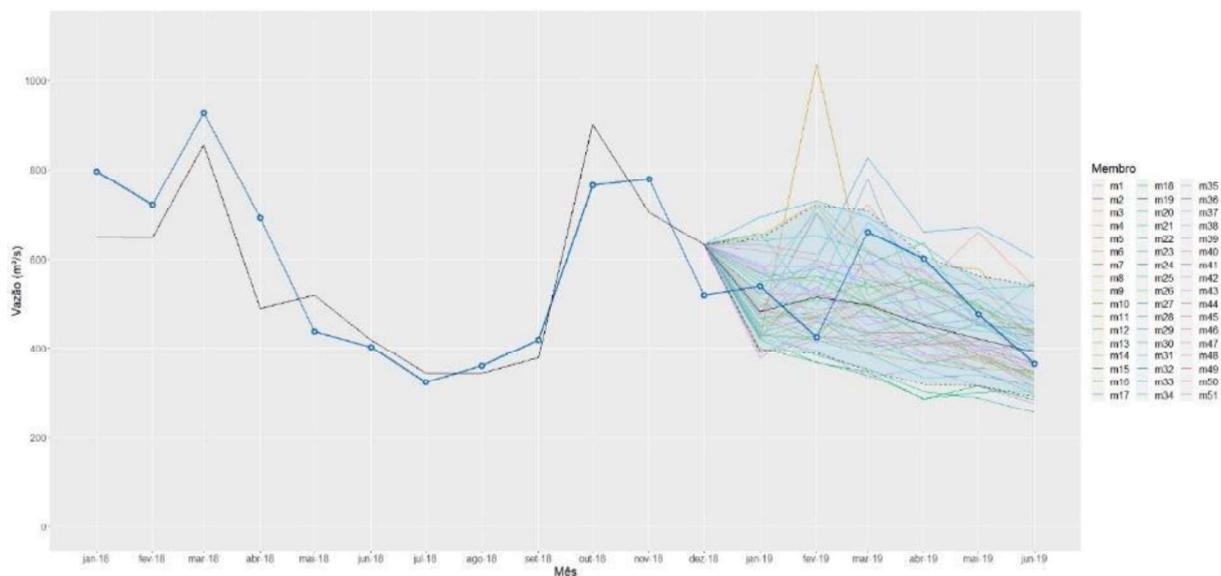


Figura AP.33 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em janeiro/2019.

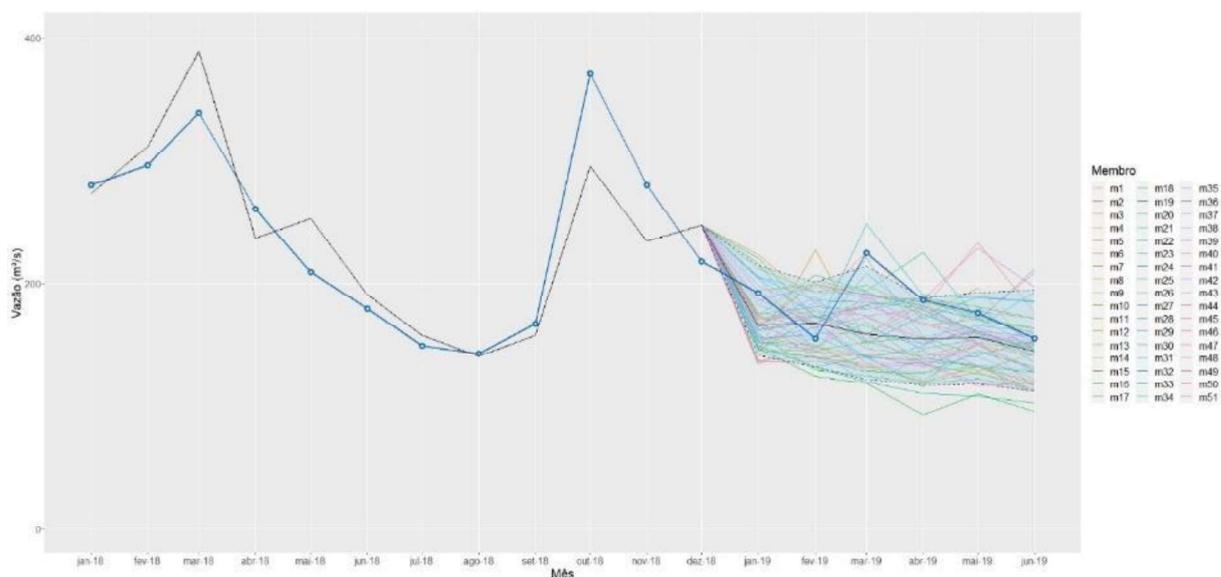


Figura AP.34 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em janeiro/2019.

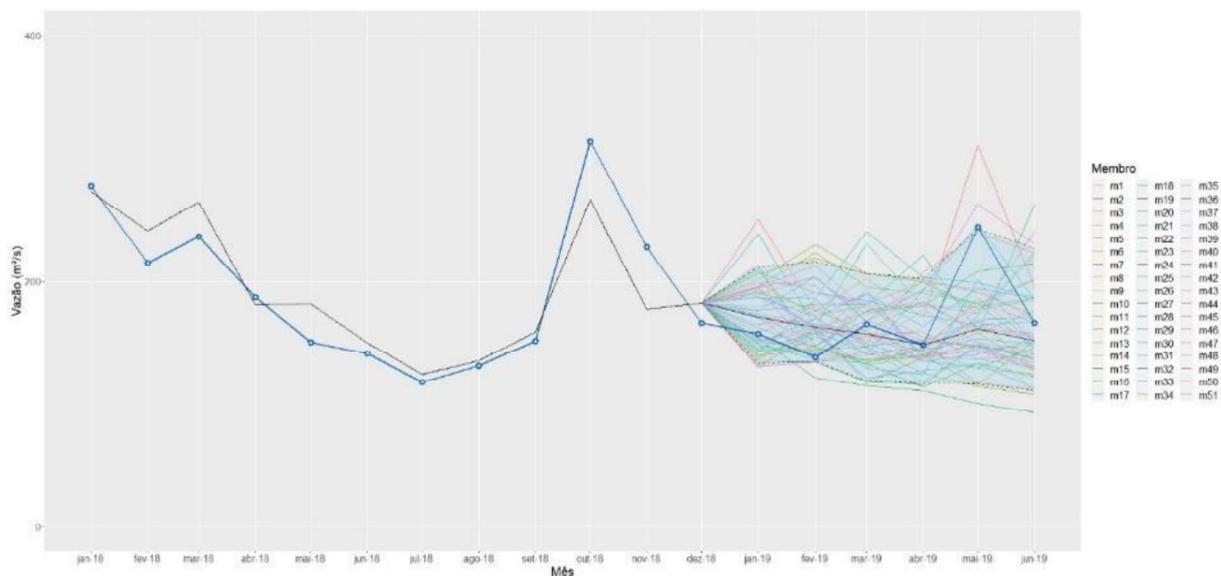


Figura AP.35 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em janeiro/2019.

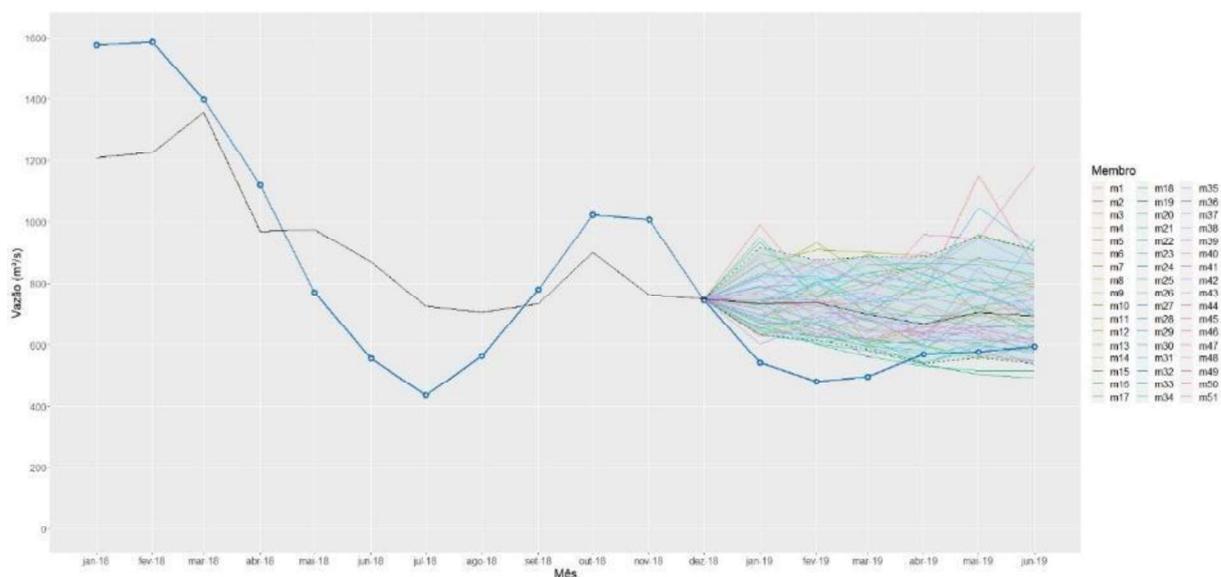


Figura AP.36 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em janeiro/2019.

APÊNDICE A7: PRECIPITAÇÃO PREVISTA COM INÍCIO EM FEVEREIRO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

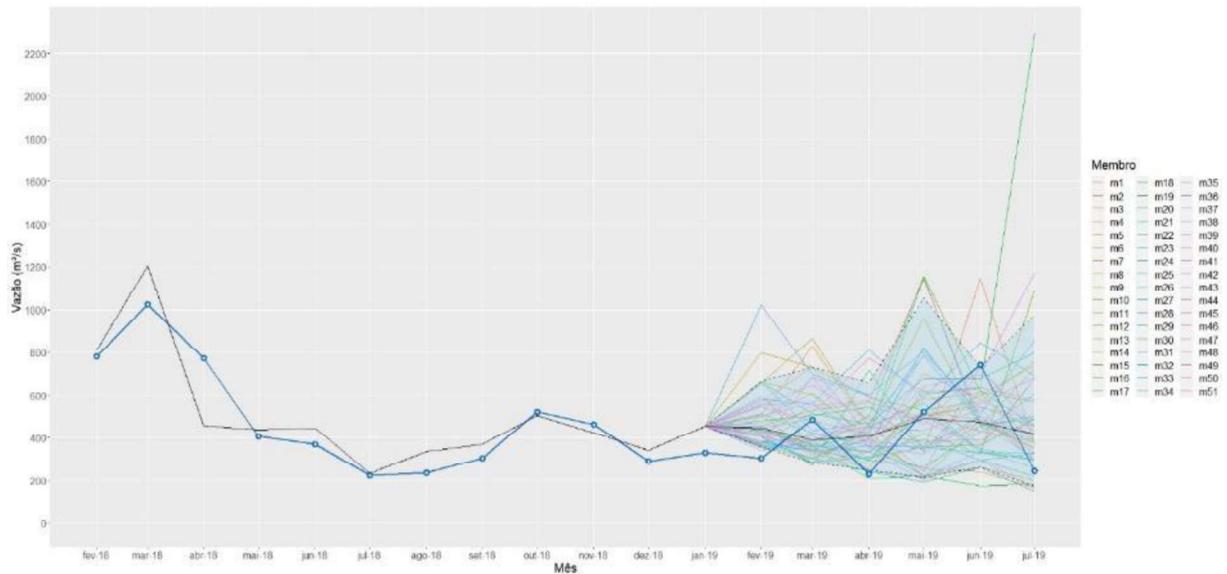


Figura AP.37 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em fevereiro/2019.

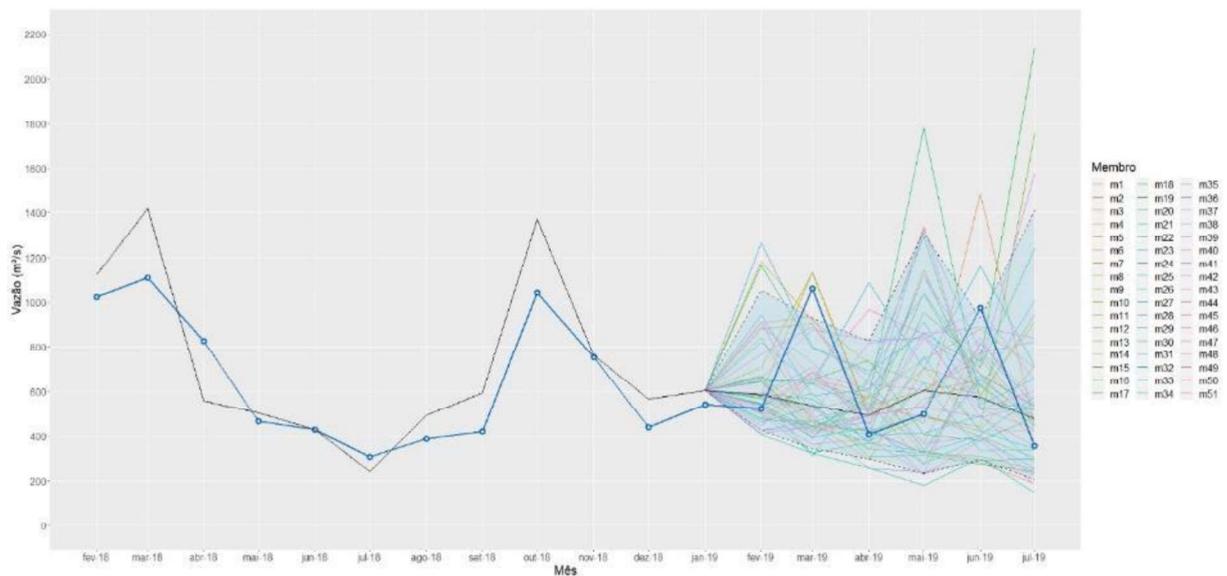


Figura AP.38 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em fevereiro/2019.

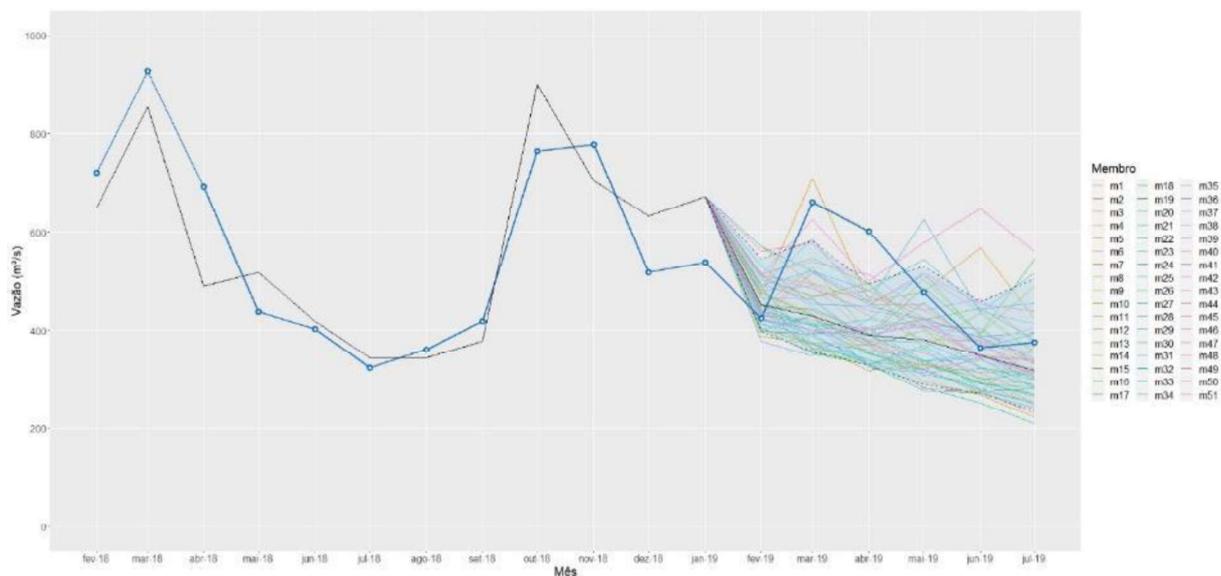


Figura AP.39 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em fevereiro/2019.

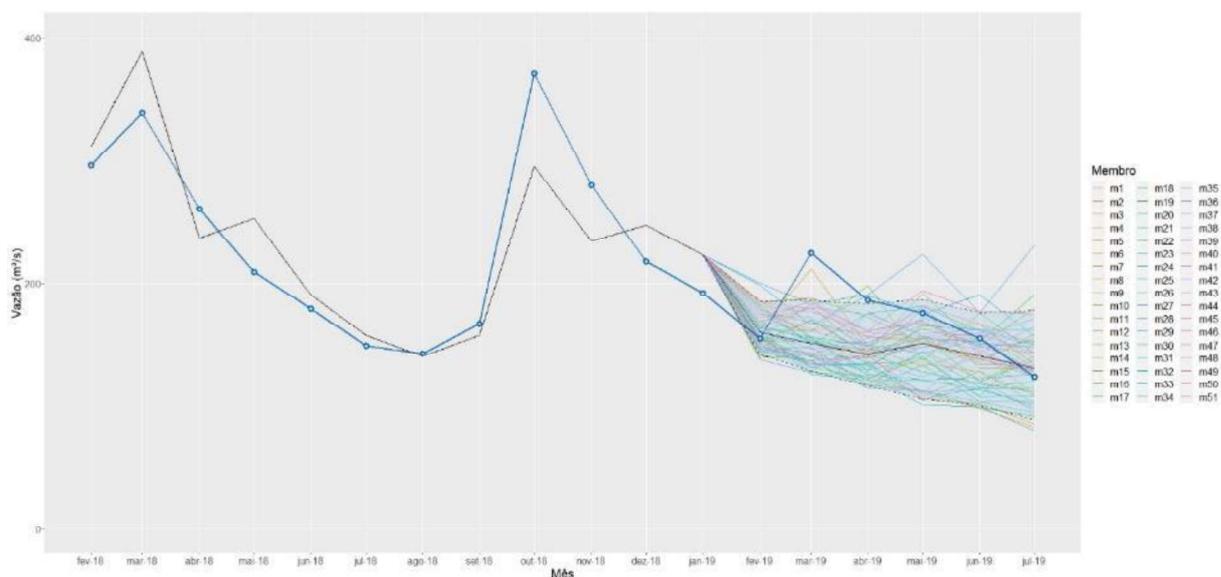


Figura AP.40 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em fevereiro/2019.

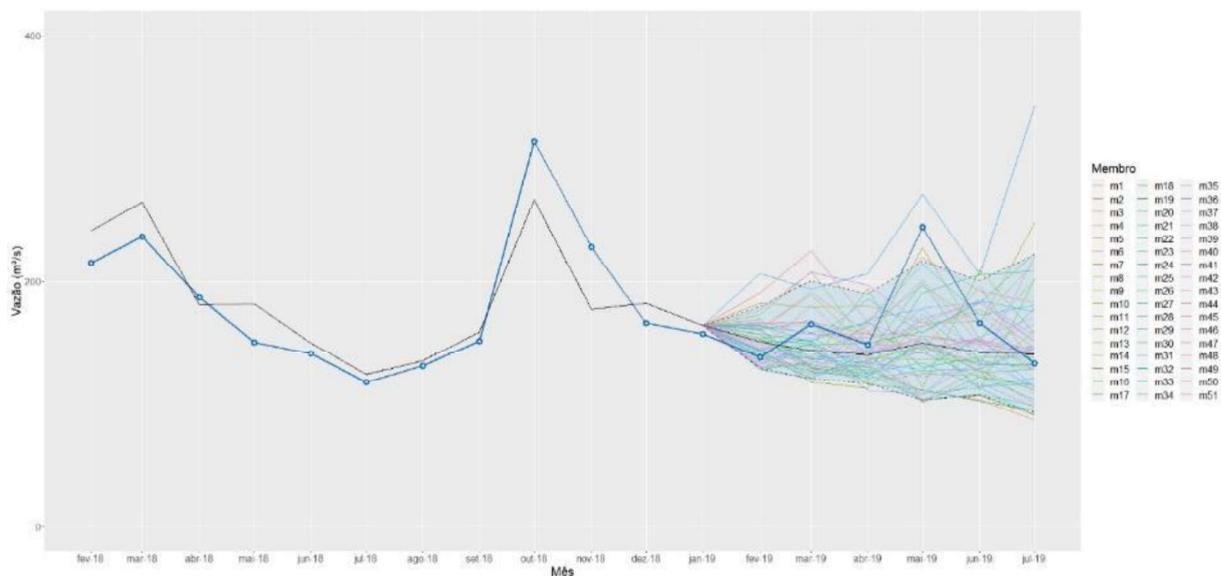


Figura AP.41 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em fevereiro/2019.

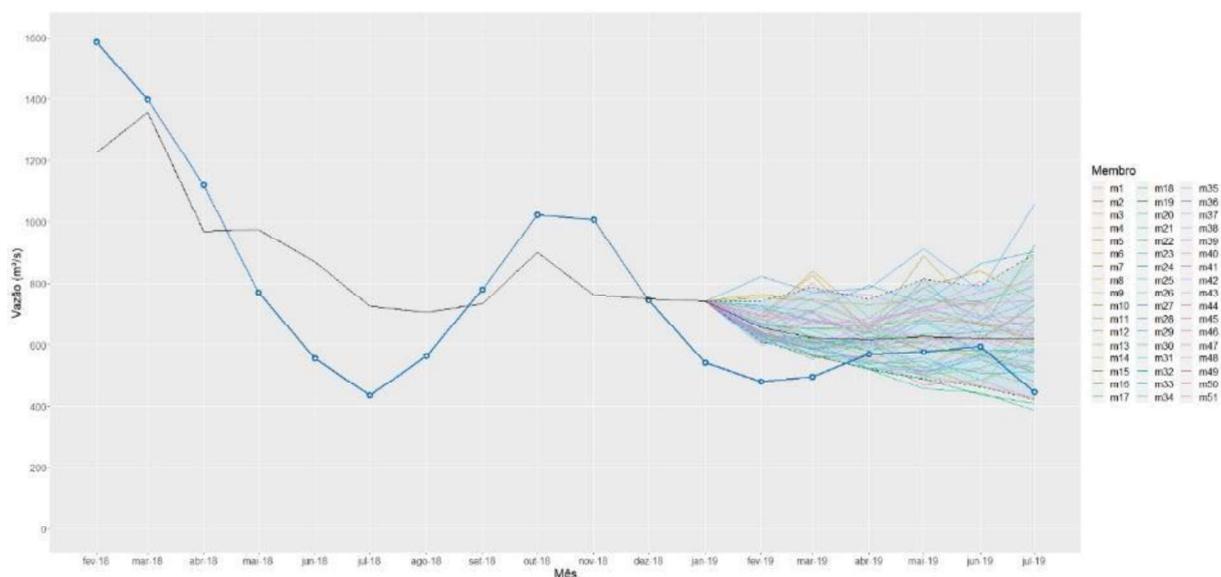


Figura AP.42 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em fevereiro/2019.

APÊNDICE A8: PRECIPITAÇÃO PREVISTA COM INÍCIO EM MARÇO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

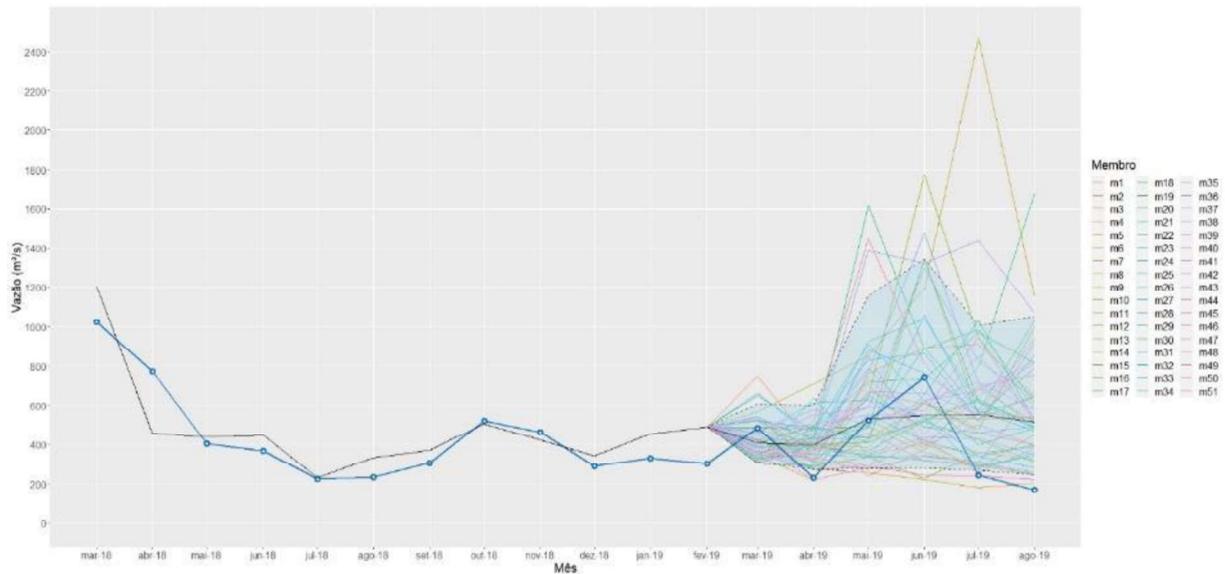


Figura AP.43 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em março/2019.

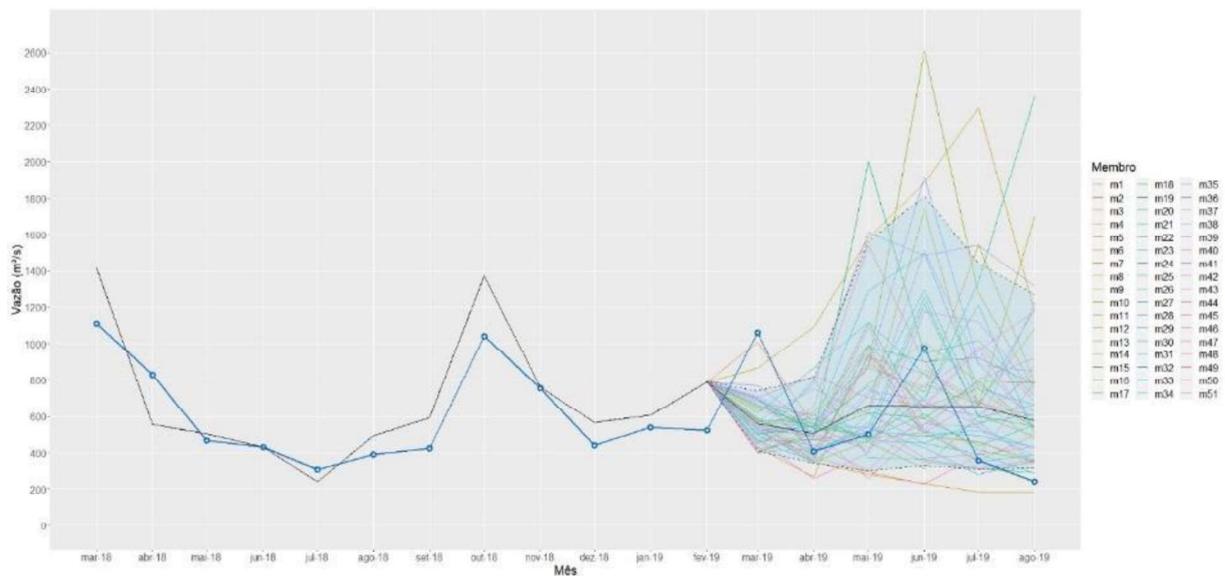


Figura AP.44 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em março/2019.

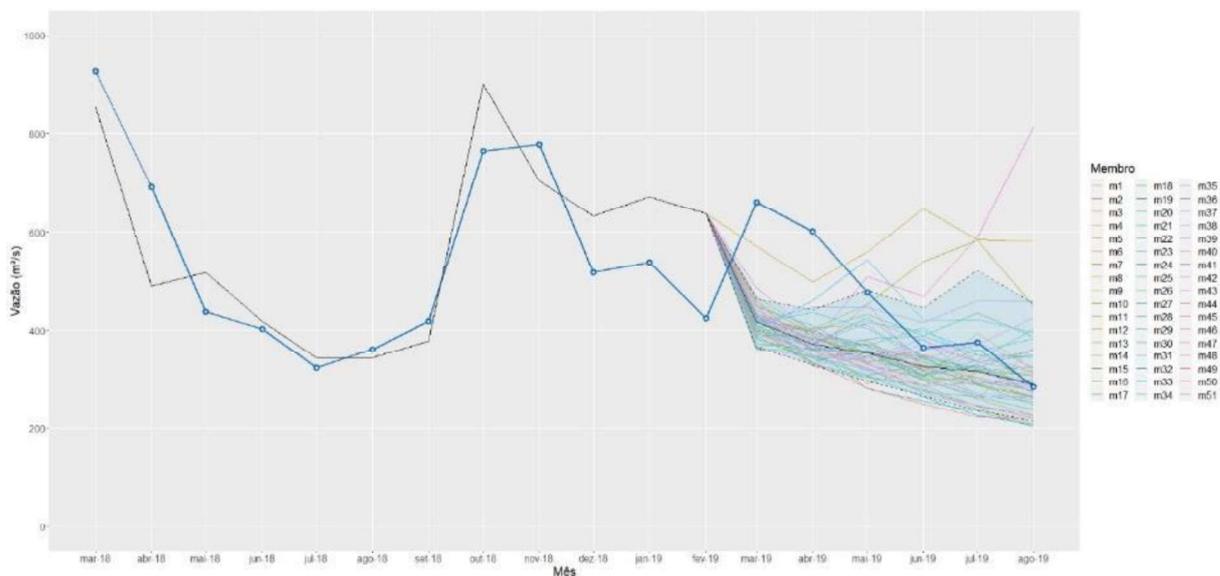


Figura AP.45 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em março/2019.

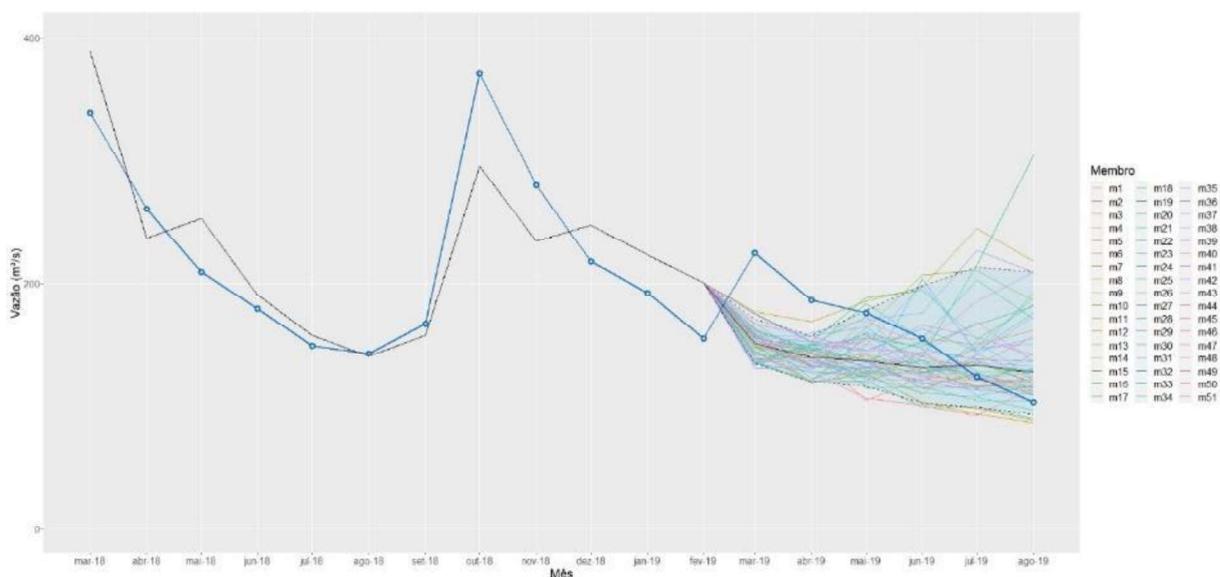


Figura AP.46 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em março/2019.

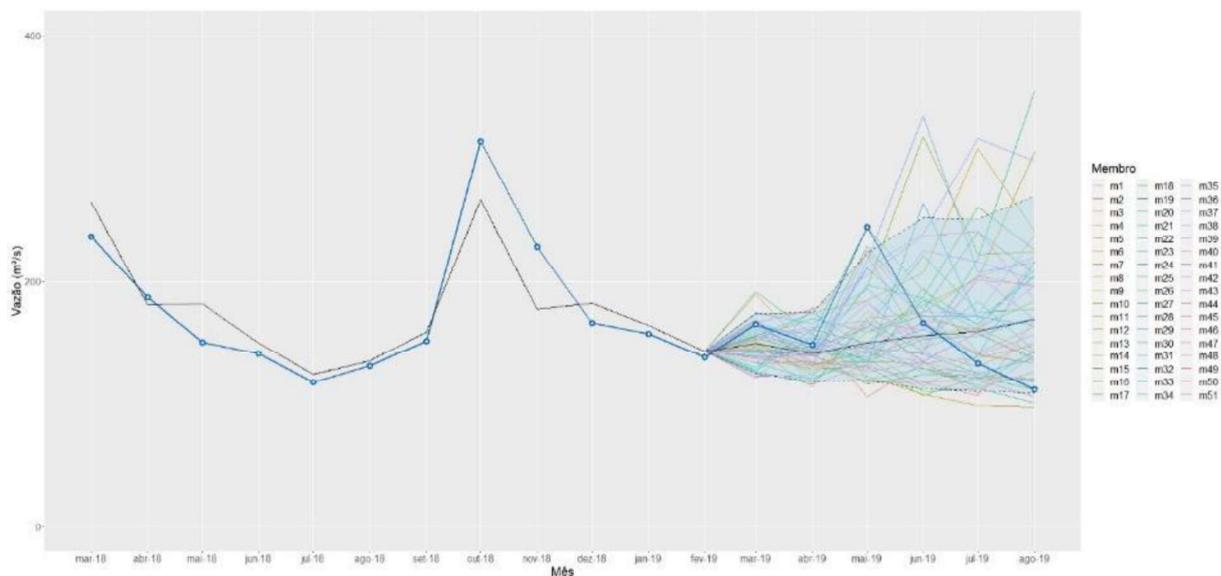


Figura AP.47 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em março/2019.

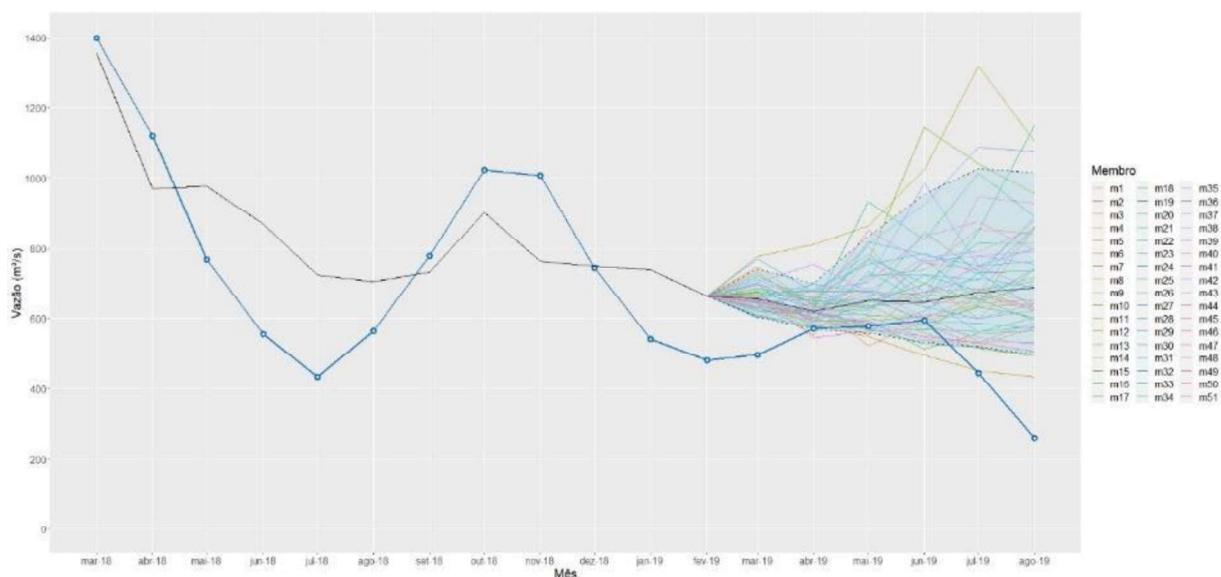


Figura AP.48 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em março/2019.

APÊNDICE A9: PRECIPITAÇÃO PREVISTA COM INÍCIO EM ABRIL/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

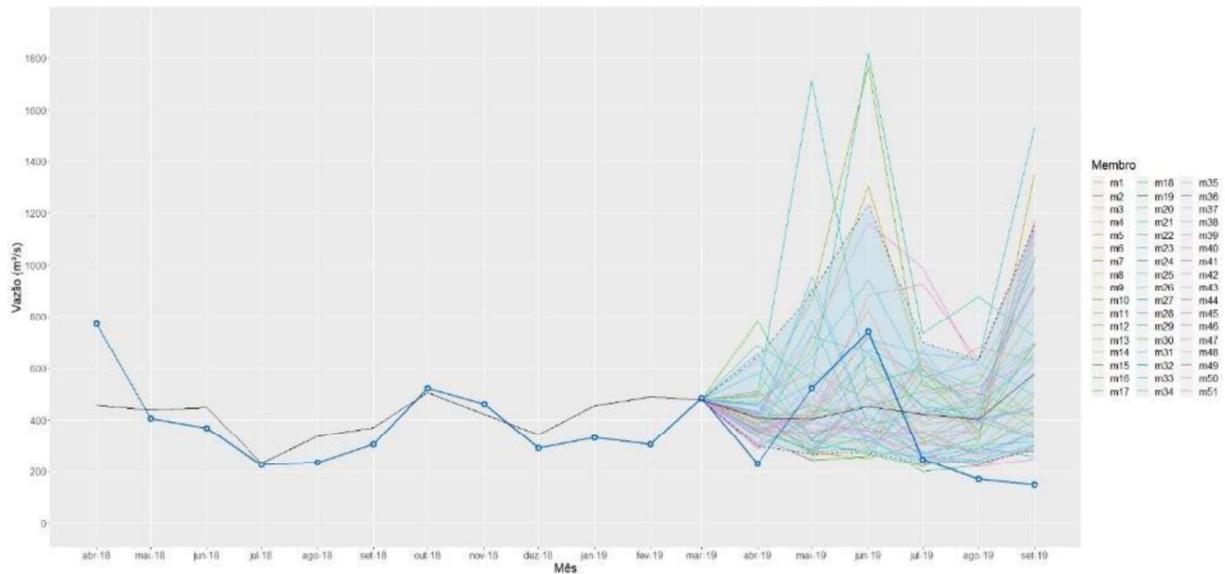


Figura AP.49 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em abril/2019.

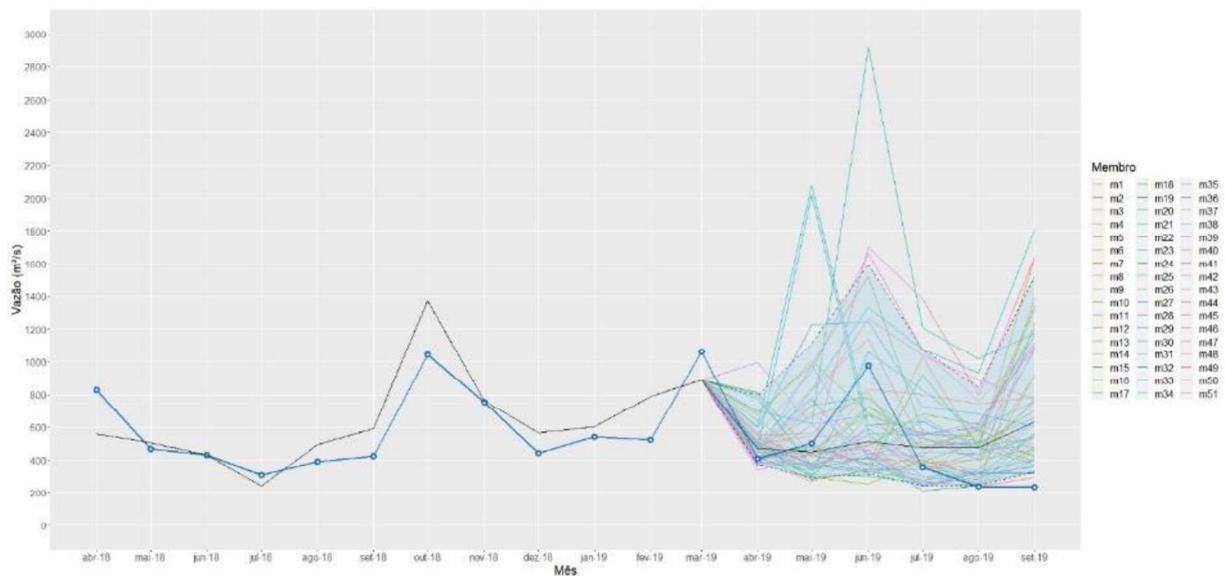


Figura AP.50 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em abril/2019.

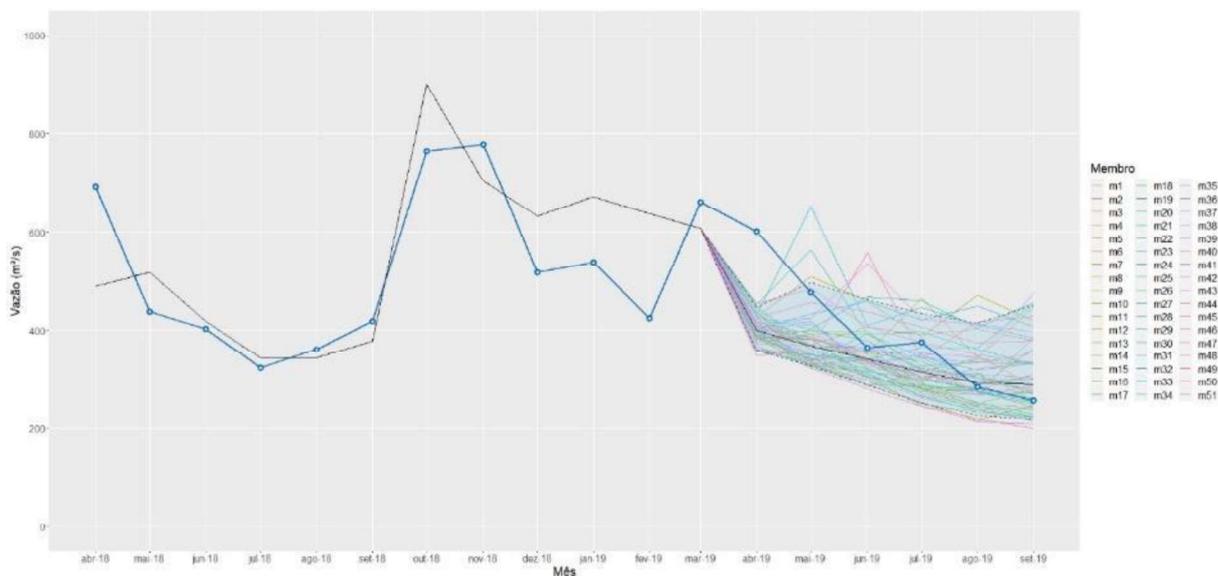


Figura AP.51 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em abril/2019.

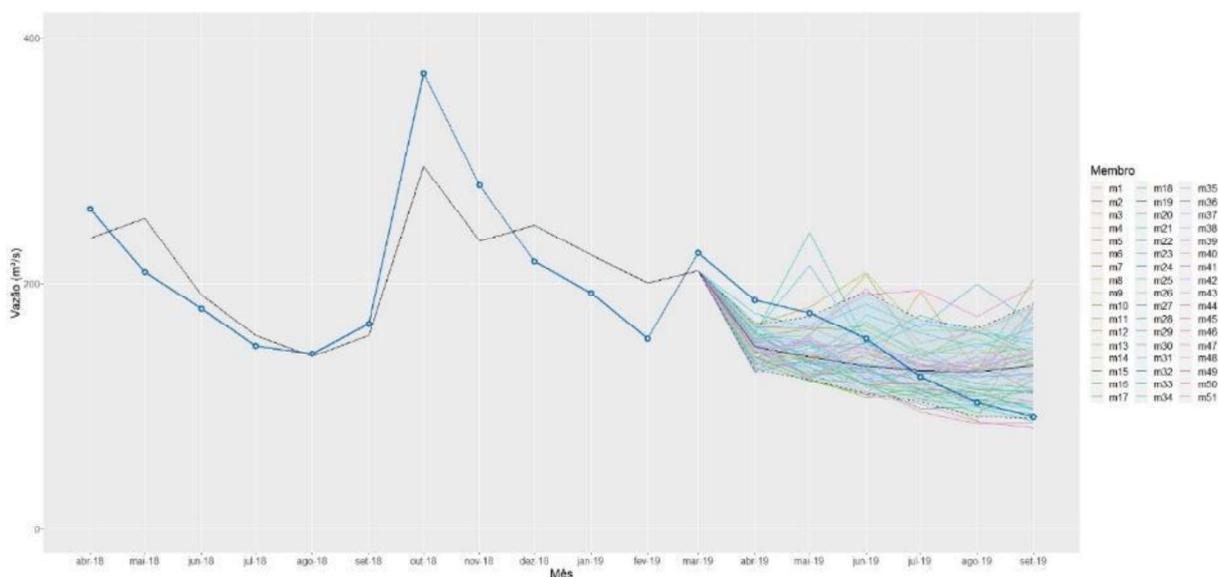


Figura AP.52 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em abril/2019.

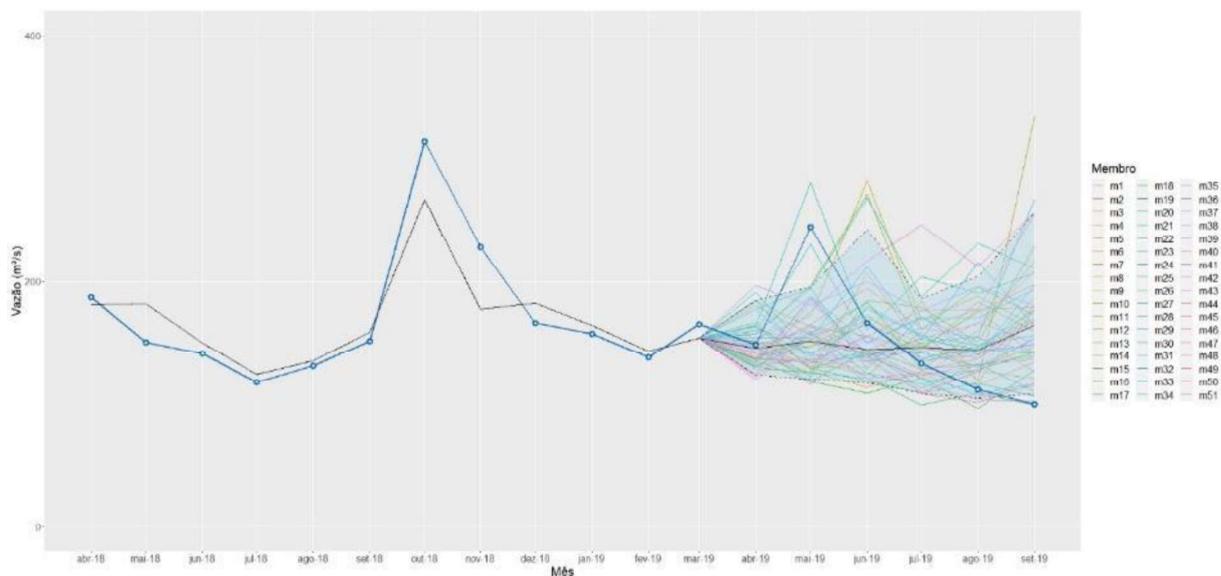


Figura AP.53 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em abril/2019.

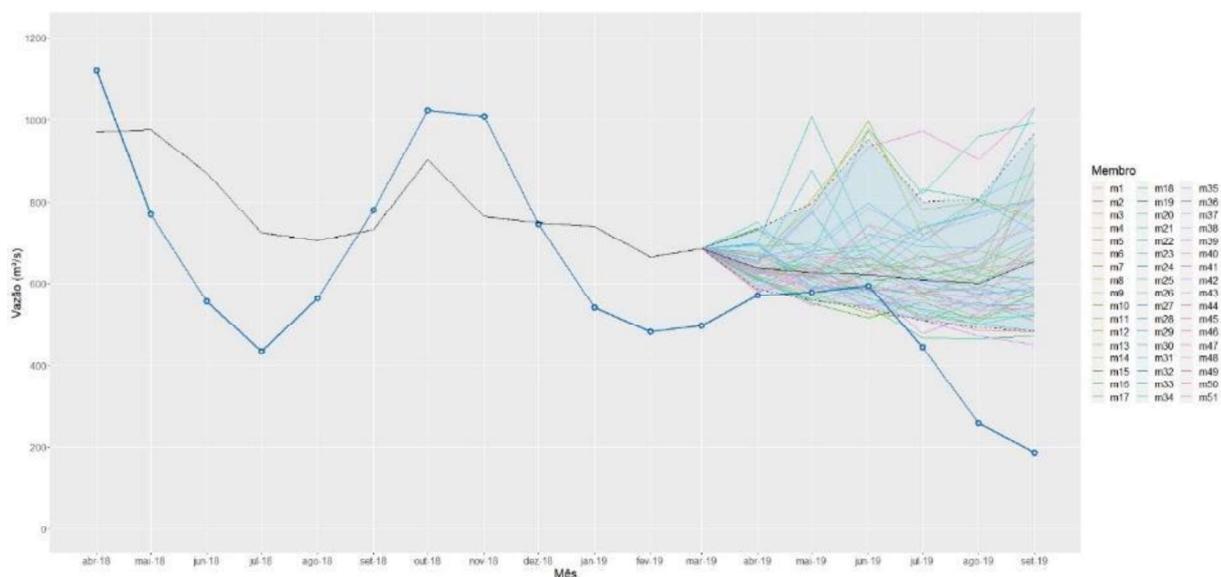


Figura AP.54 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em abril/2019.

APÊNDICE A10: PRECIPITAÇÃO PREVISTA COM INÍCIO EM MAIO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

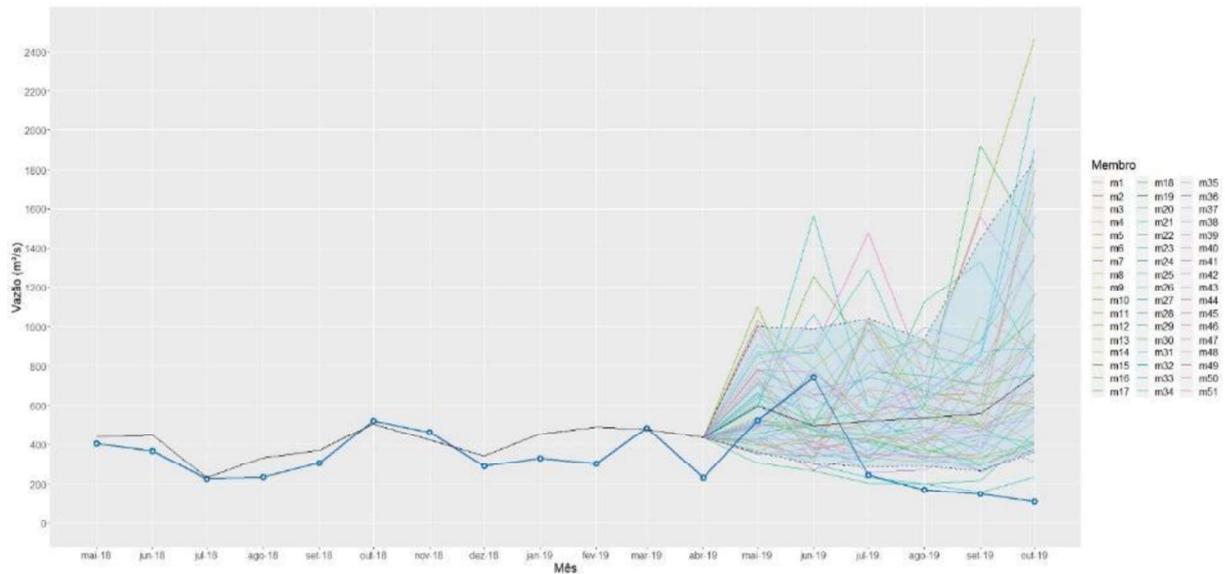


Figura AP.55 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em maio/2019.

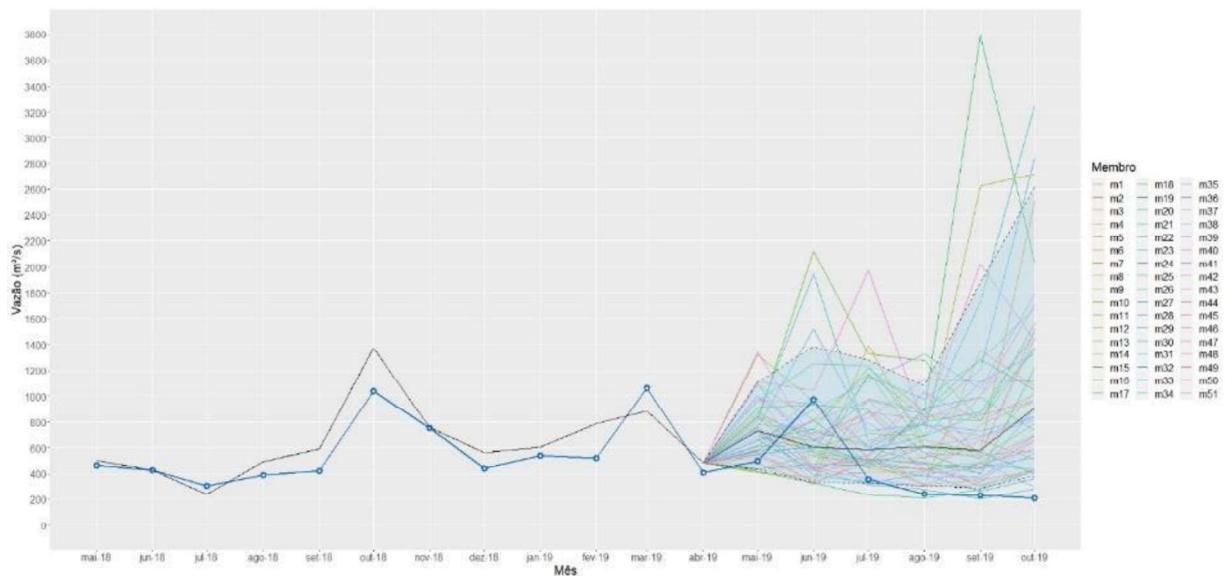


Figura AP.56 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em maio/2019.

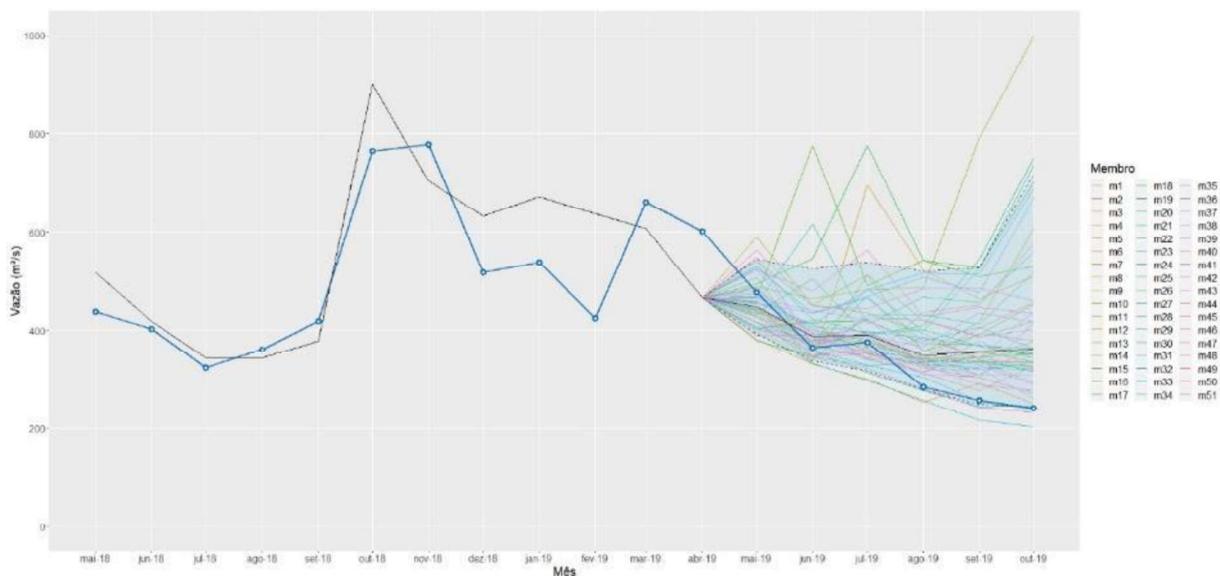


Figura AP.57 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em maio/2019.

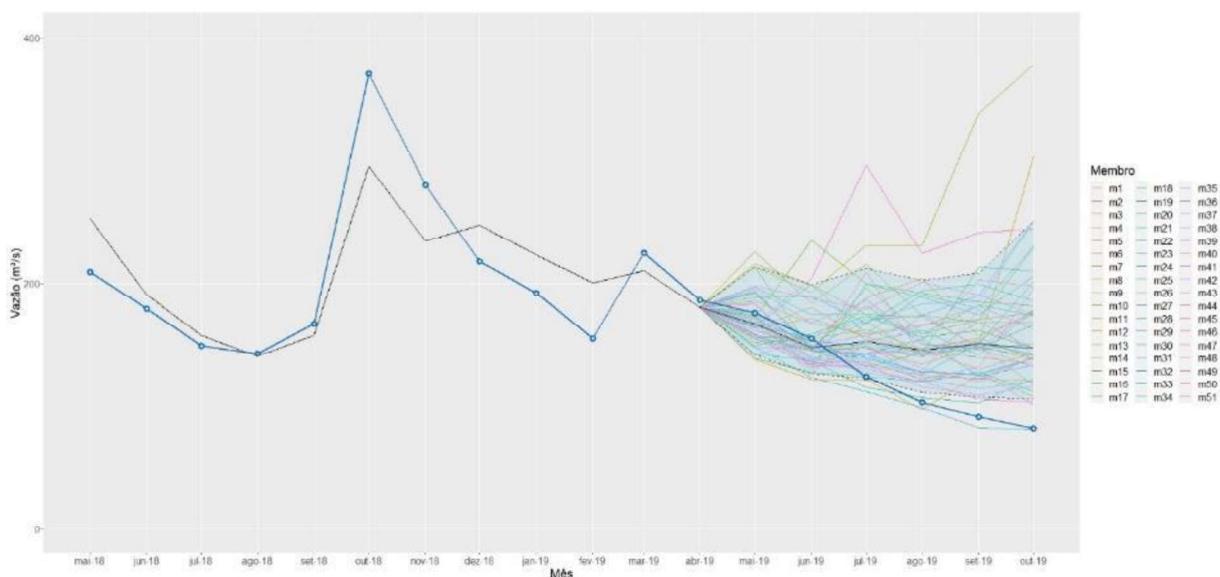


Figura AP.58 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambaí, para a previsão de precipitação iniciada em maio/2019.

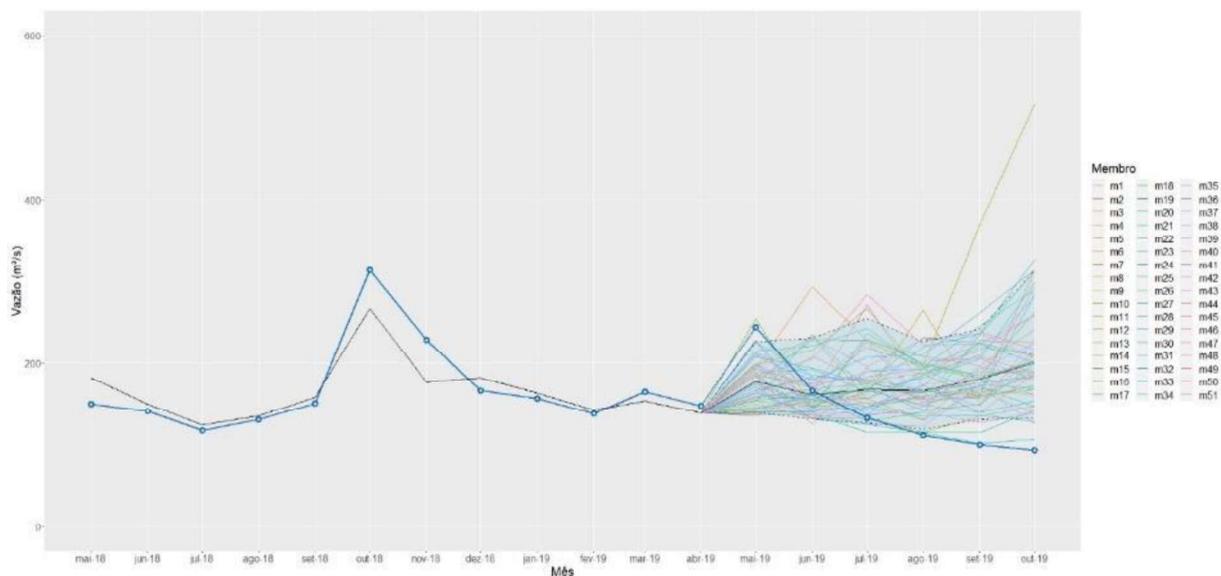


Figura AP.59 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em maio/2019.

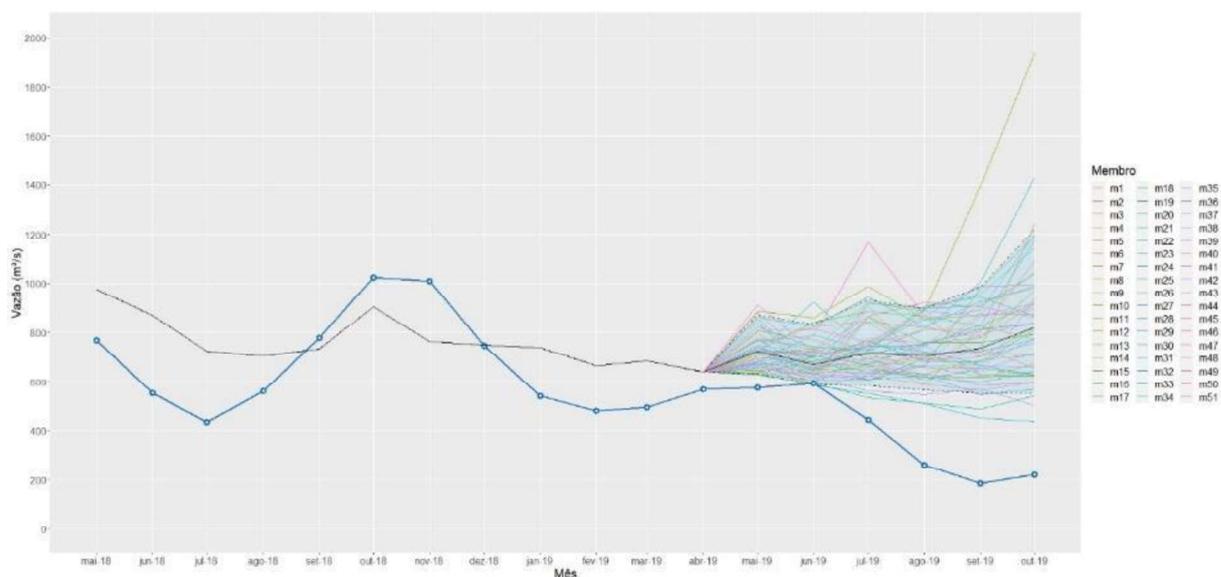


Figura AP.60 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em maio/2019.

APÊNDICE A11: PRECIPITAÇÃO PREVISTA COM INÍCIO EM JUNHO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

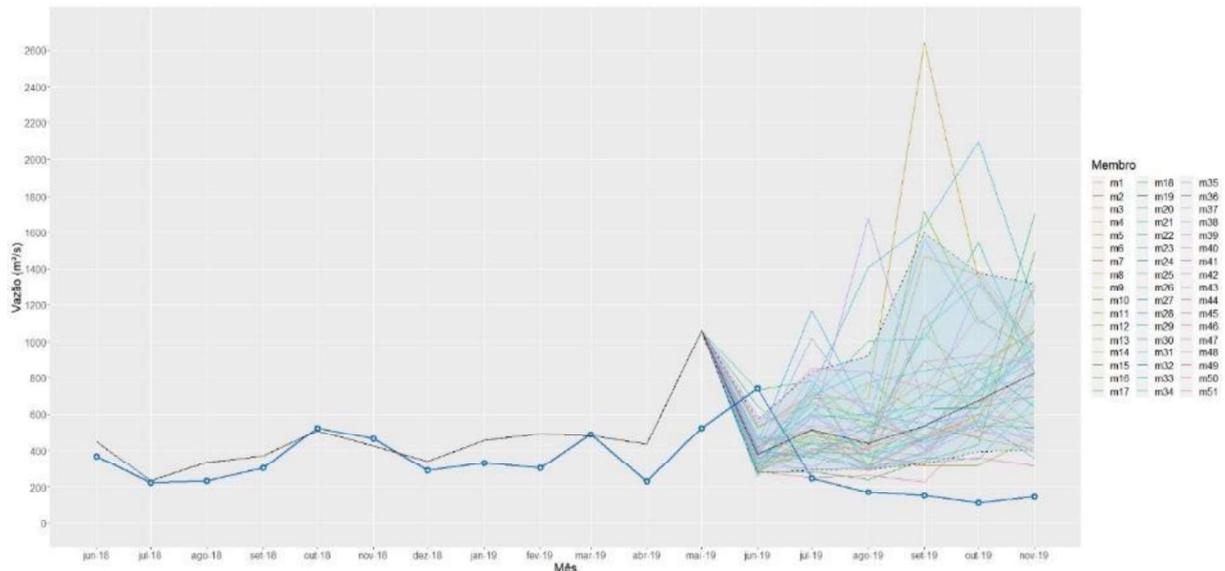


Figura AP.61 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em junho/2019.

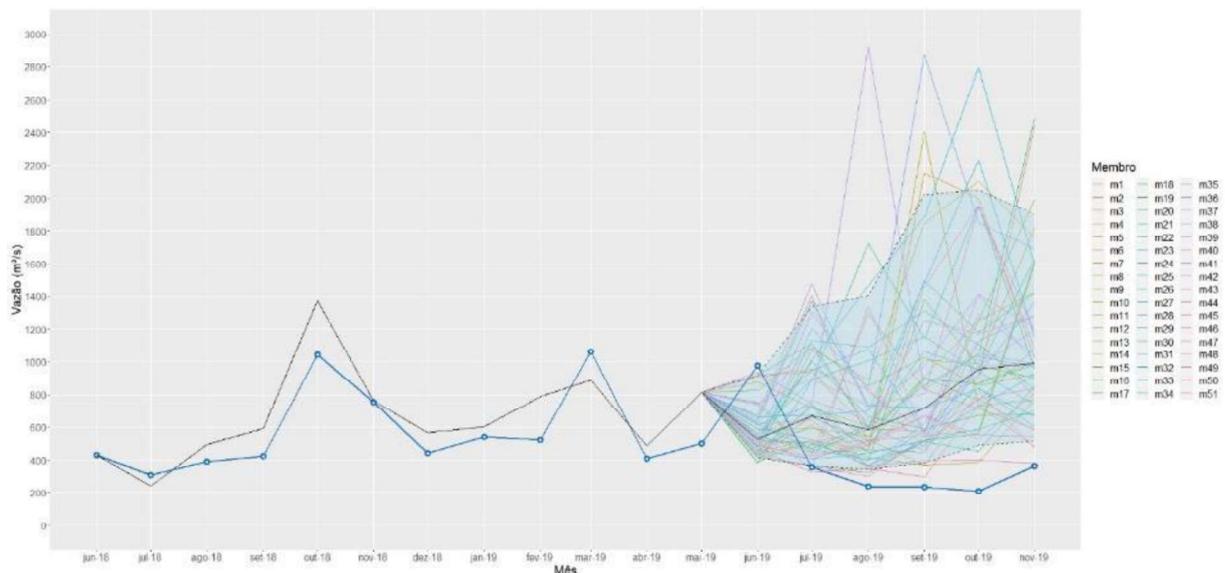


Figura AP.62 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em junho/2019.

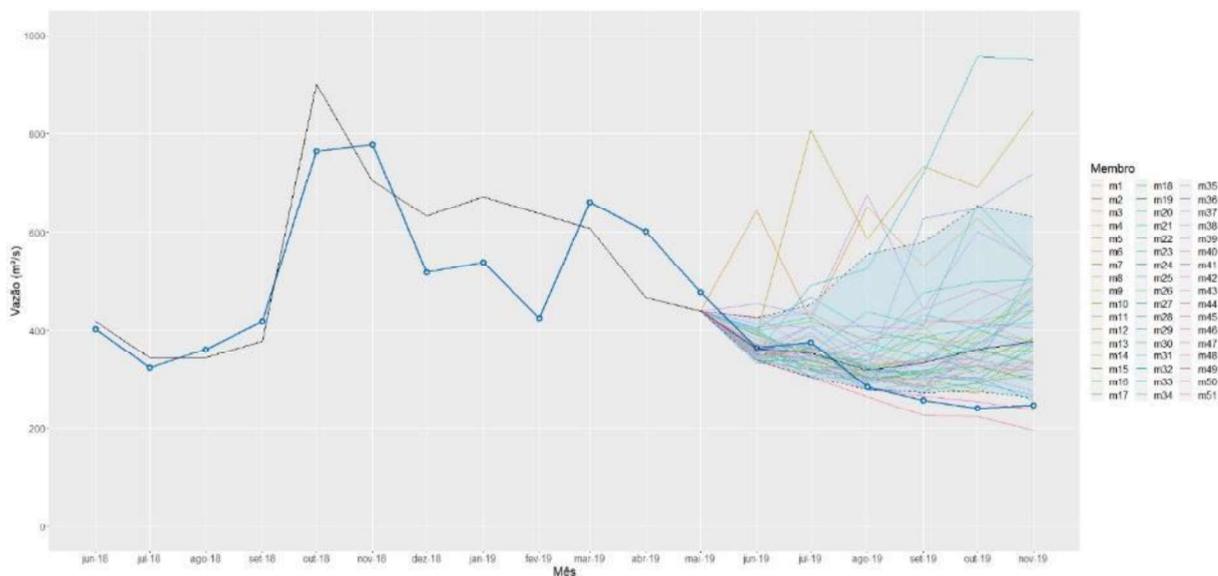


Figura AP.63 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em junho/2019.

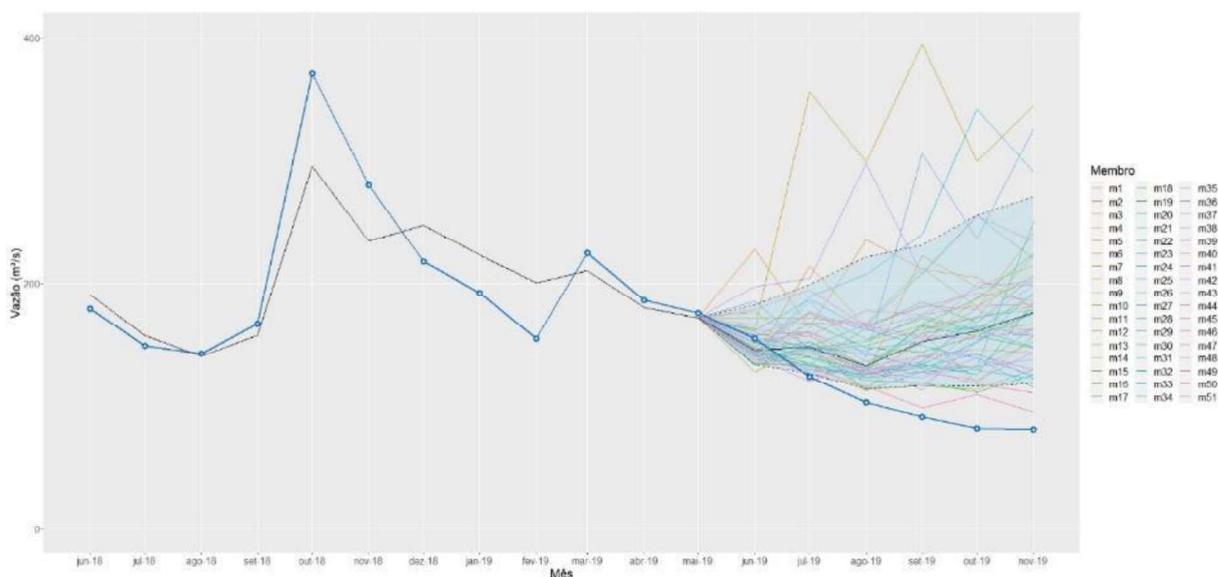


Figura AP.64 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em junho/2019.

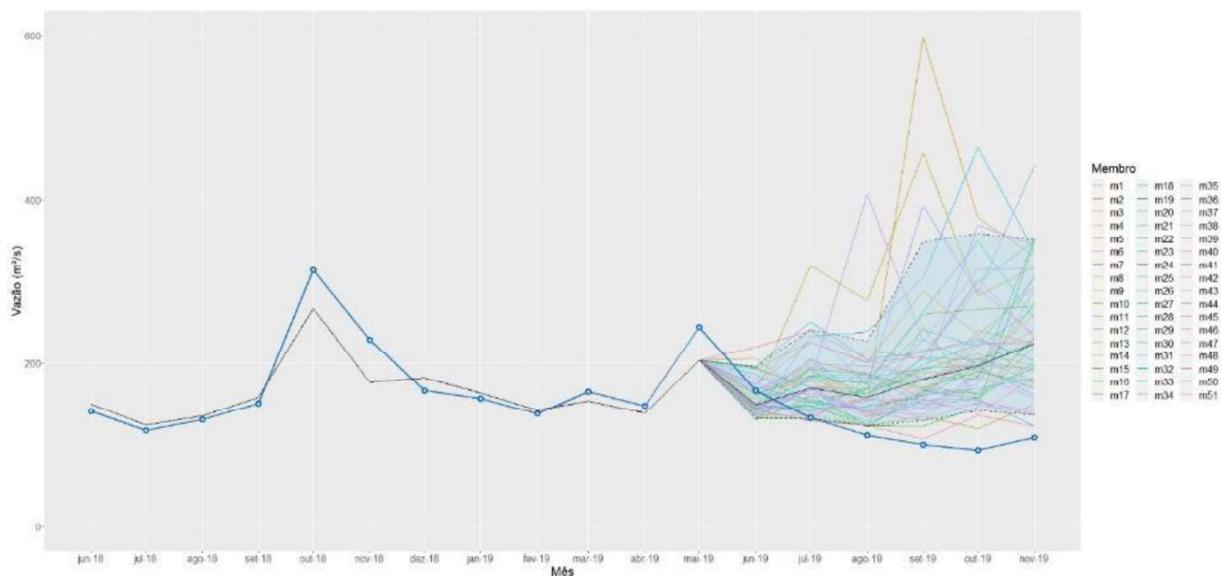


Figura AP.65 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em junho/2019.

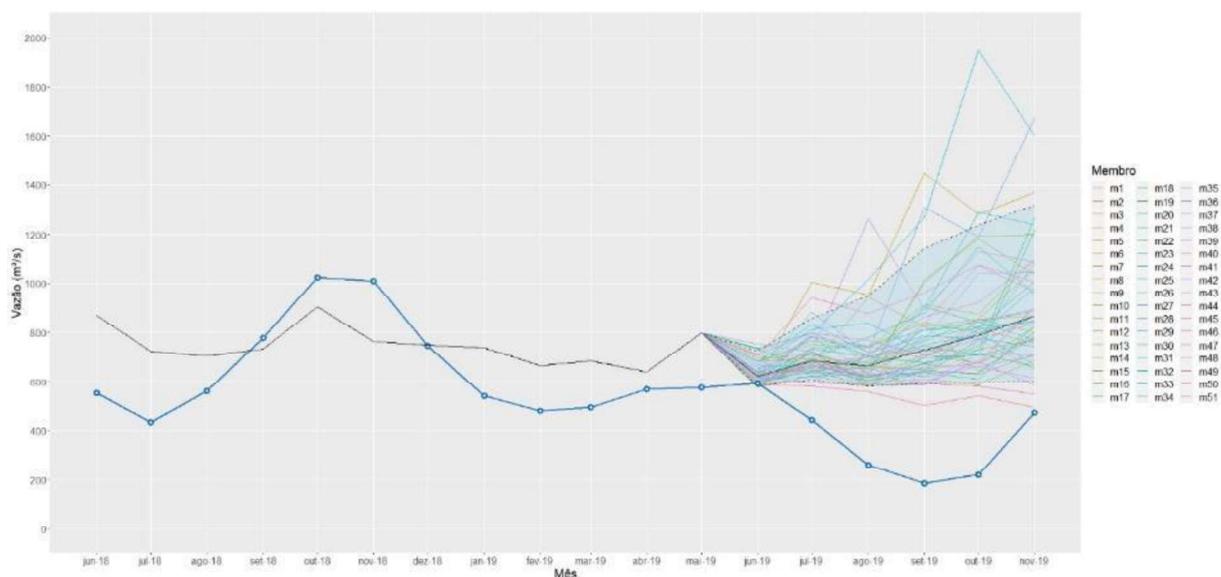


Figura AP.66 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em junho/2019.

APÊNDICE A12: PRECIPITAÇÃO PREVISTA COM INÍCIO EM JULHO/2019

Nos gráficos a seguir são apresentadas, para cada sub-bacia modelada, a série de vazões mensais observadas nos últimos 18 meses (linha azul), a ponderação das simulações pela Equação (4.11) (linha preta) e o ESP das séries (membros) de vazão prevista \bar{Q}_t^k (linhas coloridas), das quais obteve-se o IC de 90% (área hachurada) e a mediana (linha preta).

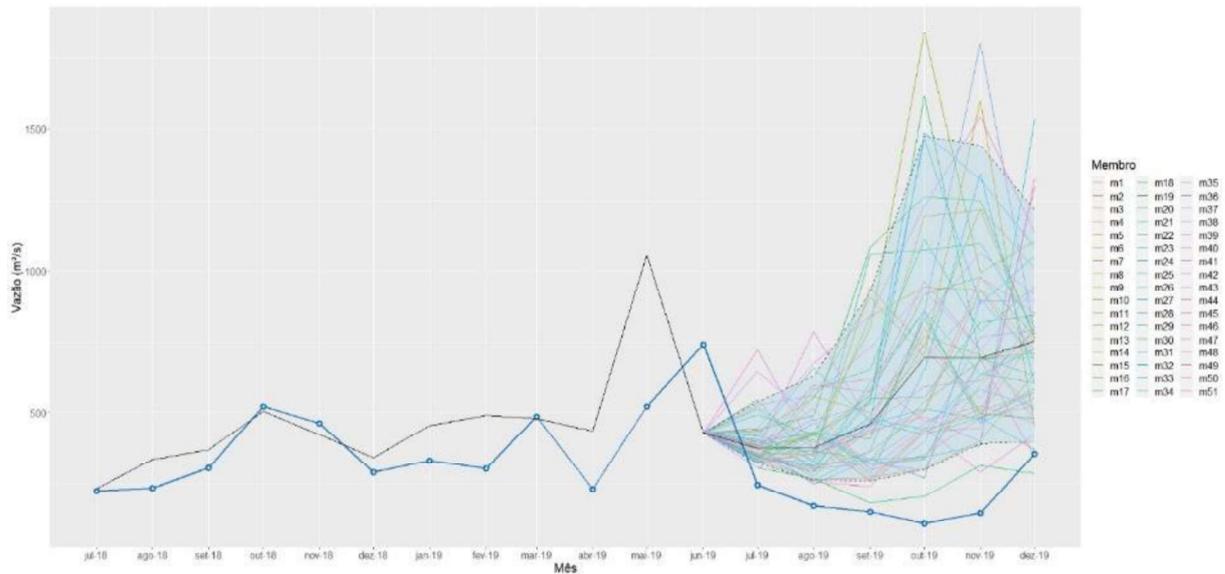


Figura AP.67 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Piquiri, para a previsão de precipitação iniciada em julho/2019.

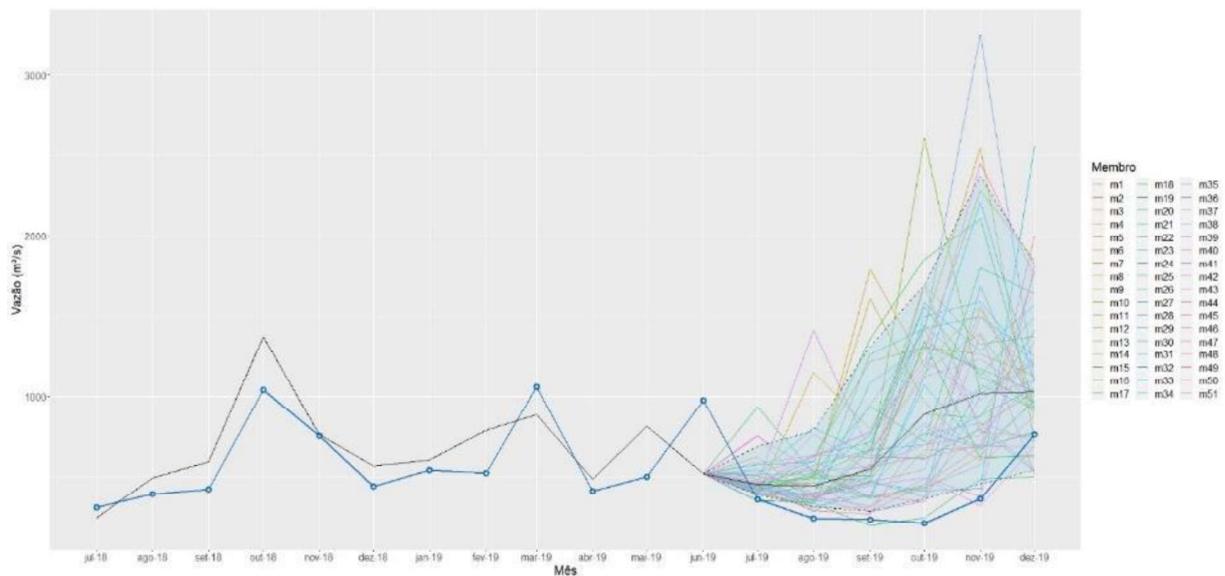


Figura AP.68 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivaí, para a previsão de precipitação iniciada em julho/2019.

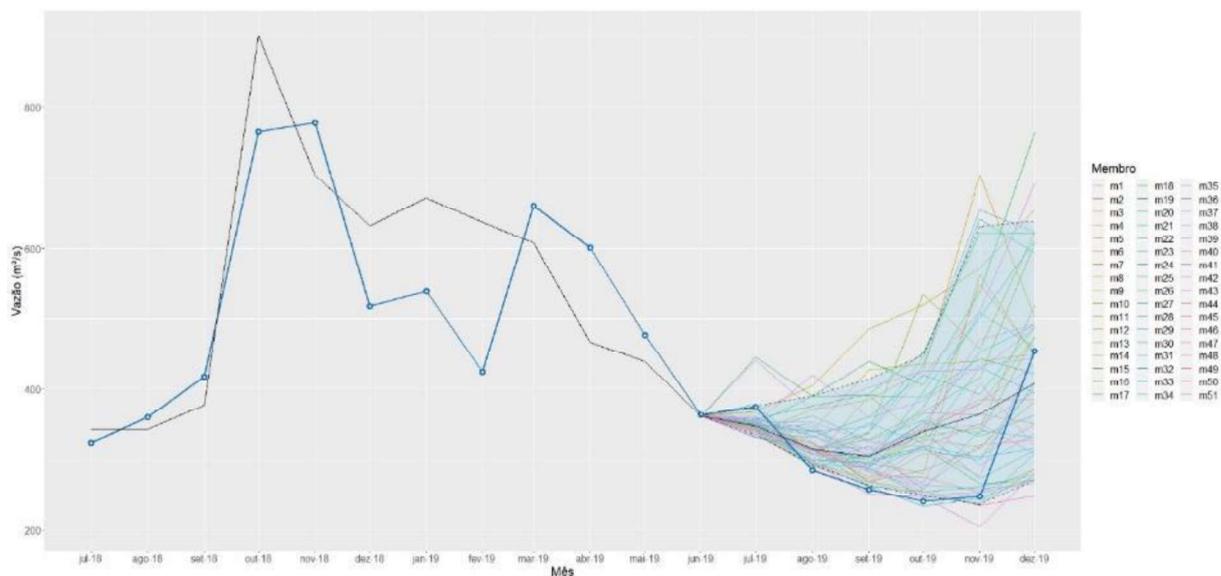


Figura AP.69 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Ivinhema, para a previsão de precipitação iniciada em julho/2019.

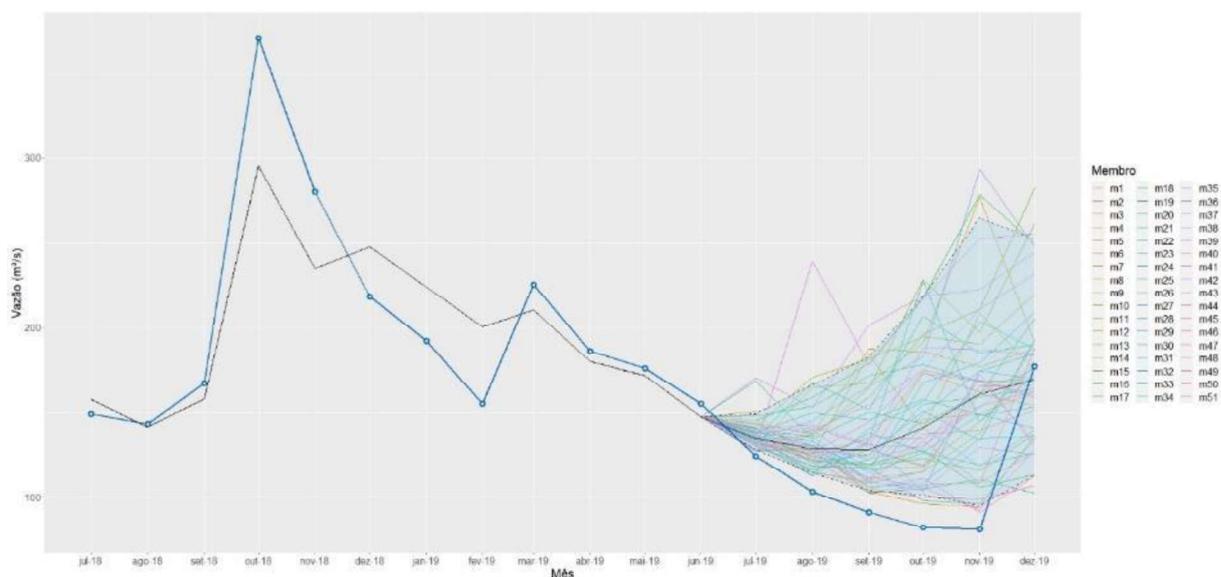


Figura AP.70 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Amambá, para a previsão de precipitação iniciada em julho/2019.

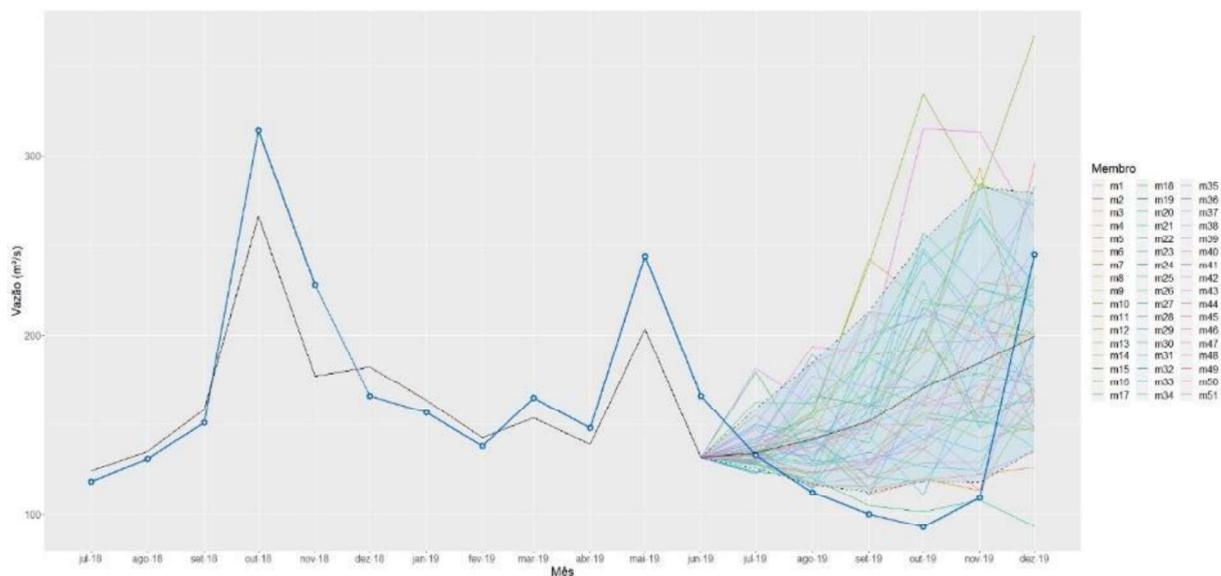


Figura AP.71 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia do rio Iguatemi, para a previsão de precipitação iniciada em julho/2019.

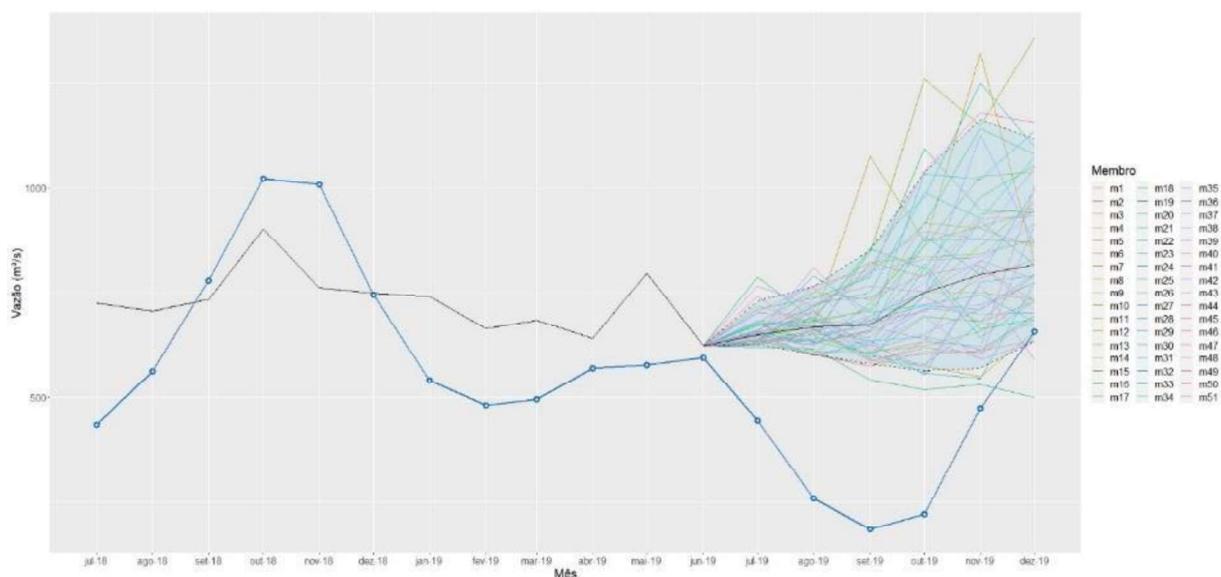


Figura AP.72 - Vazões médias mensais observadas e previstas (ESP) para a sub-bacia “não-monitorada”, para a previsão de precipitação iniciada em julho/2019.

**APÊNDICE B: DESEMPENHO DA MEDIANA DAS PREVISÕES DE CADA
SUB-BACIA MODELADA, PARA AS SÉRIES DE PRECIPITAÇÃO PREVISTA**

APÊNDICE B1: DESEMPENHO GLOBAL DA MEDIANA DAS PREVISÕES

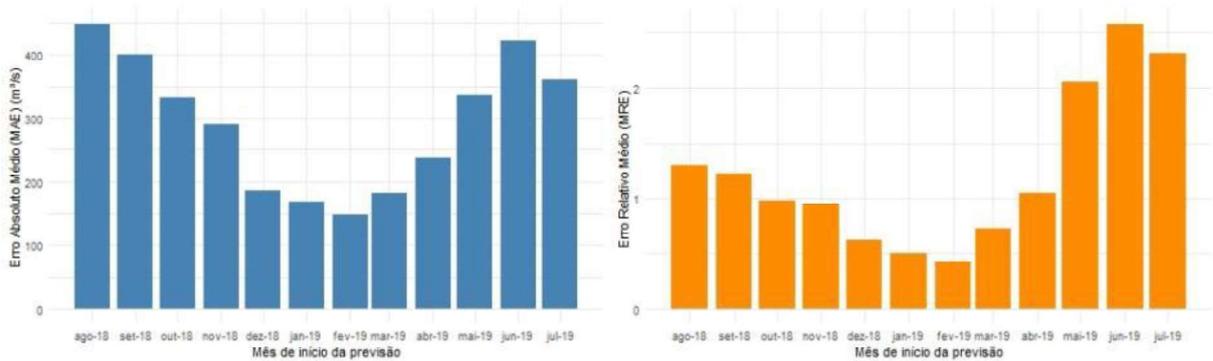


Figura AP.73 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Piquiri para todo o horizonte previsto, para cada mês de início da previsão.

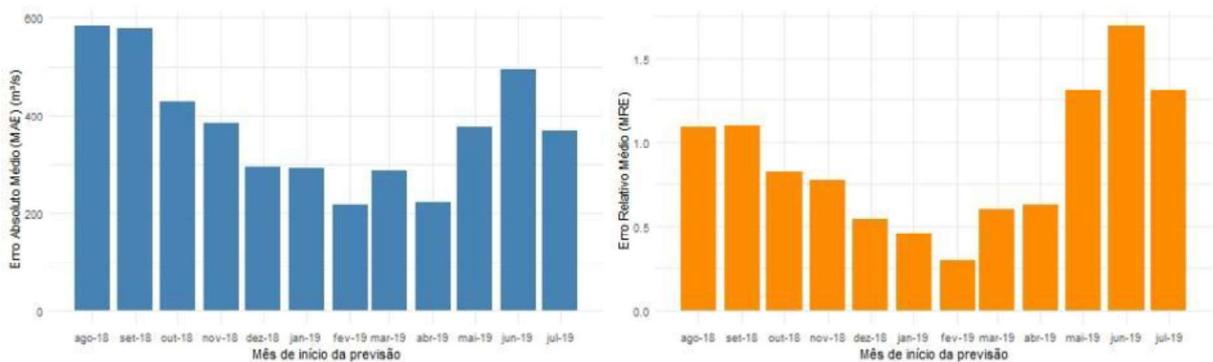


Figura AP.74 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Ivaí para todo o horizonte previsto, para cada mês de início da previsão.

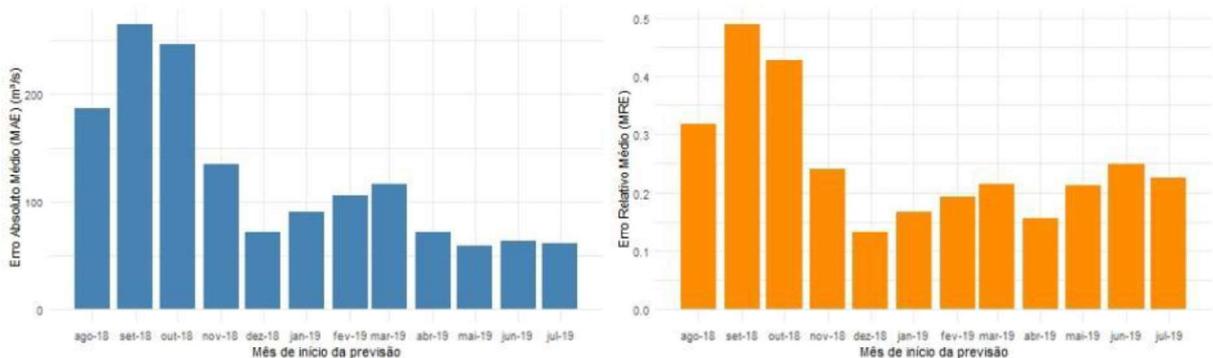


Figura AP.75 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Ivinhema para todo o horizonte previsto, para cada mês de início da previsão.

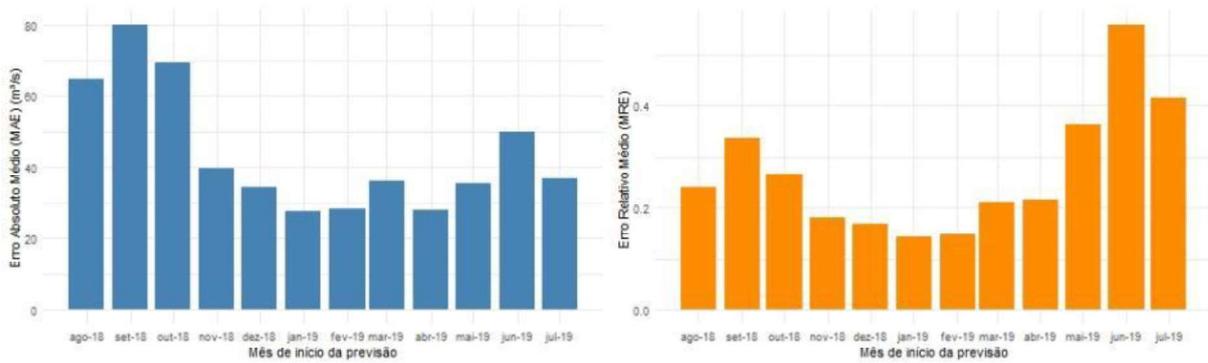


Figura AP.76 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Amambai para todo o horizonte previsto, para cada mês de início da previsão.

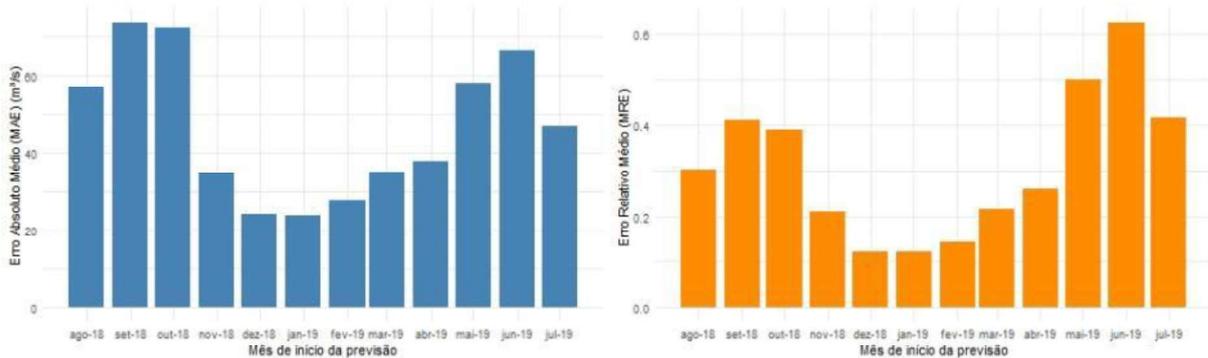


Figura AP.77 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia do rio Iguatemi para todo o horizonte previsto, para cada mês de início da previsão.

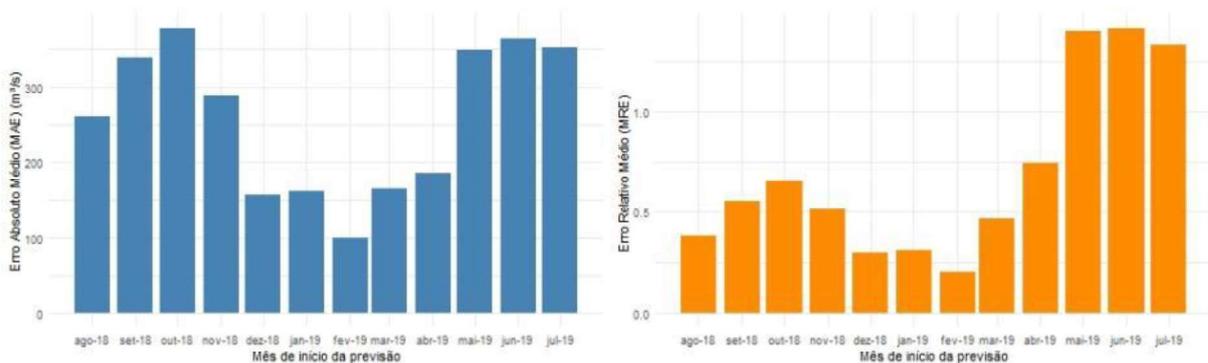


Figura AP.78 - Desempenho global (MAE e MRE) da mediana das previsões probabilísticas da sub-bacia “não-monitorada” para todo o horizonte previsto, para cada mês de início da previsão.

APÊNDICE B2: DESEMPENHO DA MEDIANA DAS PREVISÕES PARA CADA HORIZONTE DO MÊS PREVISTO

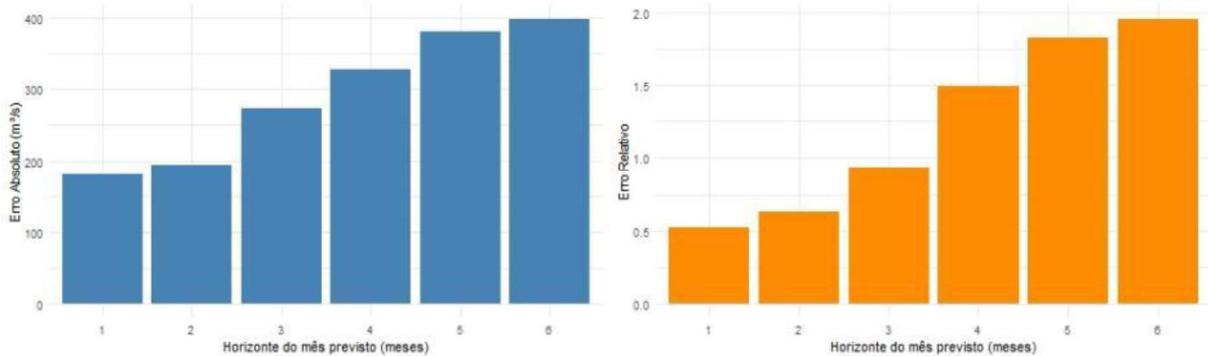


Figura AP.79 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Piquiri, para cada horizonte do mês previsto.

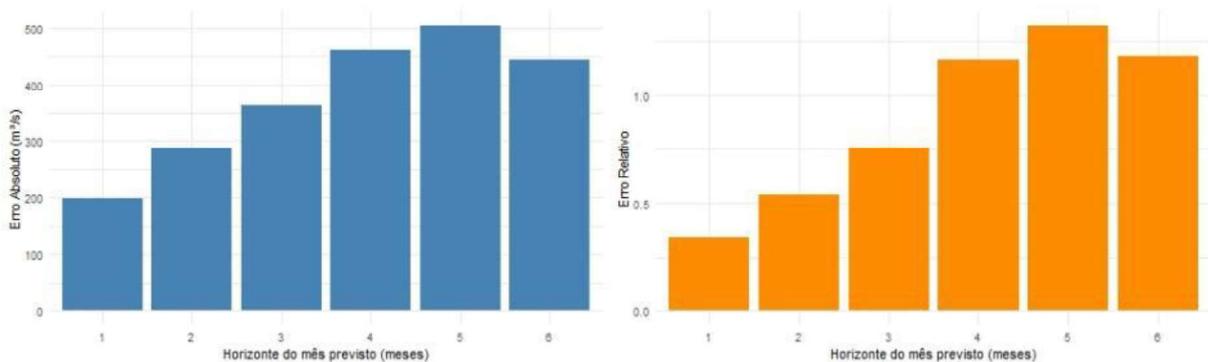


Figura AP.80 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Ivaí, para cada horizonte do mês previsto.

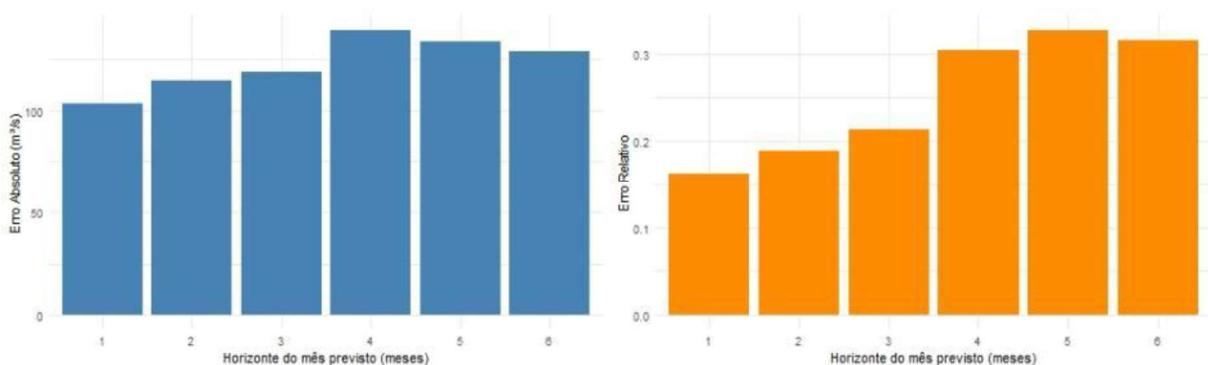


Figura AP.81 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Ivinhema, para cada horizonte do mês previsto.

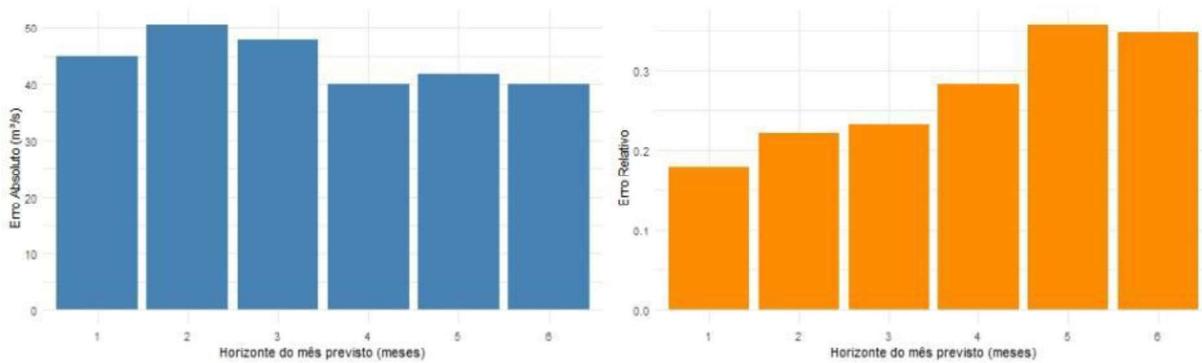


Figura AP.82 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Amambai, para cada horizonte do mês previsto.

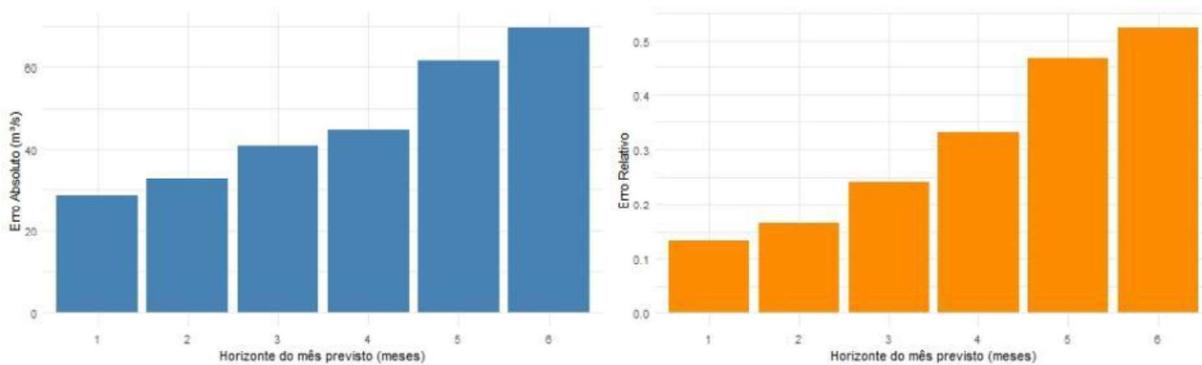


Figura AP.83 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia do rio Iguatemi, para cada horizonte do mês previsto.

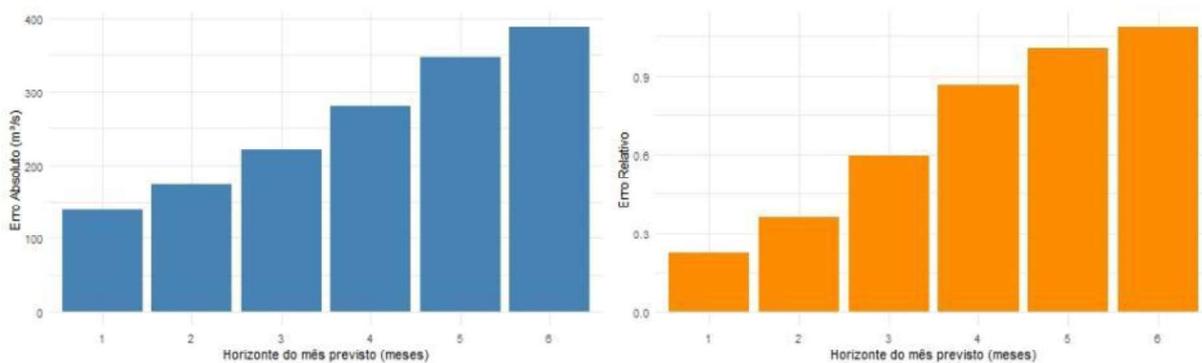


Figura AP.84 - Desempenho geral da mediana das previsões probabilísticas da sub-bacia “não-monitorada”, para cada horizonte do mês previsto.

APÊNDICE B3: EVOLUÇÃO DO DESEMPENHO DA MEDIANA DAS PREVISÕES, MÊS A MÊS

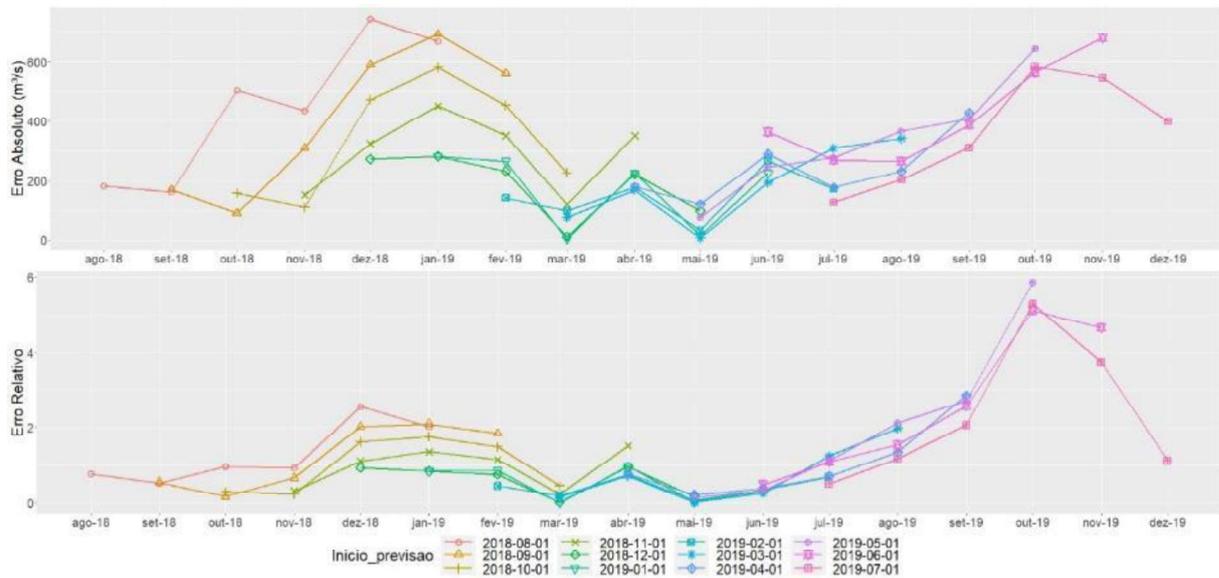


Figura AP.85 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Piquiri, mês a mês.

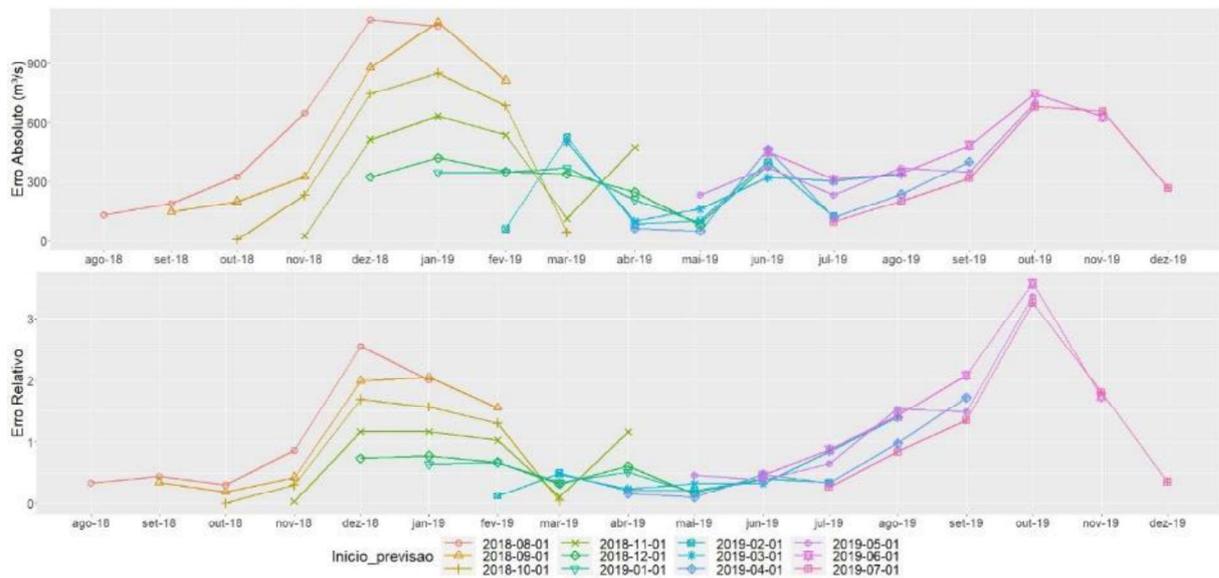


Figura AP.86 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Ivaí, mês a mês.

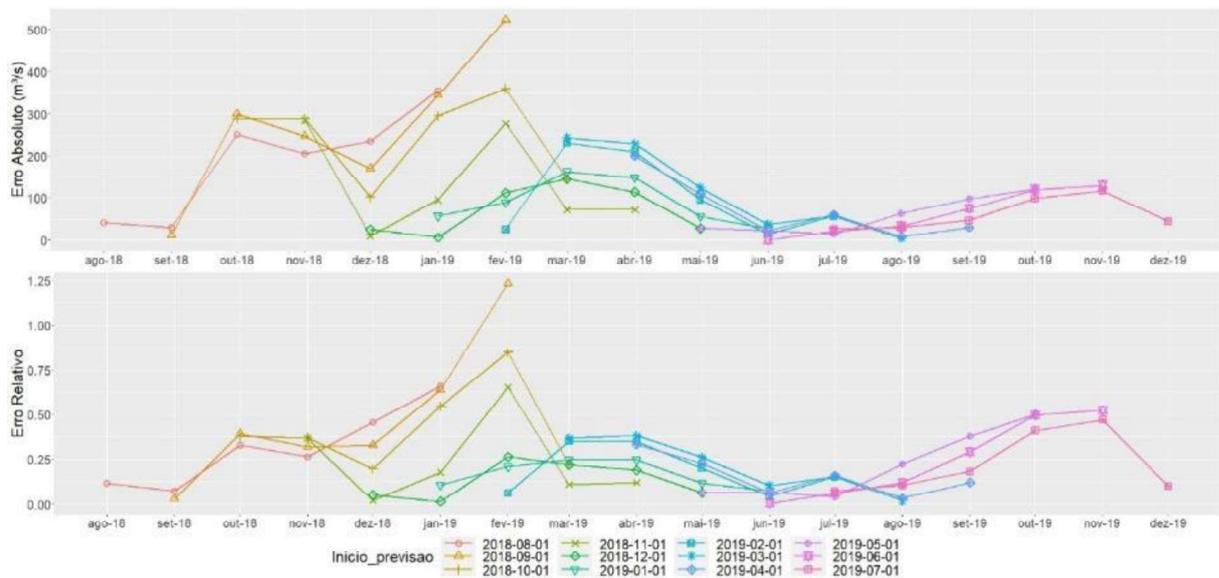


Figura AP.87 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Ivinhema, mês a mês.

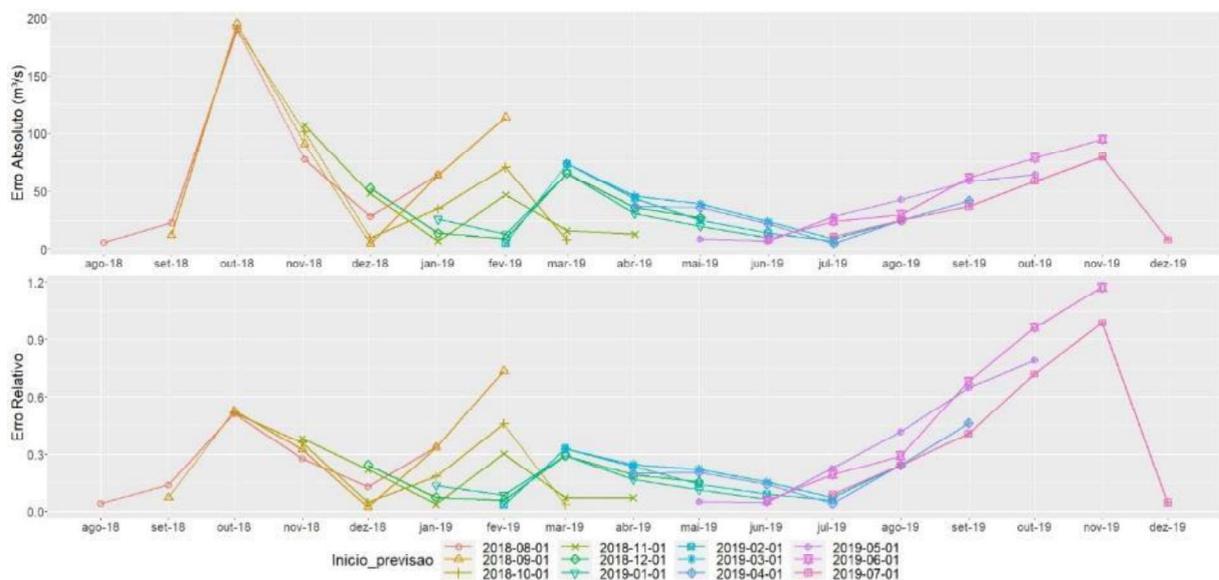


Figura AP.88 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Amambaí, mês a mês.

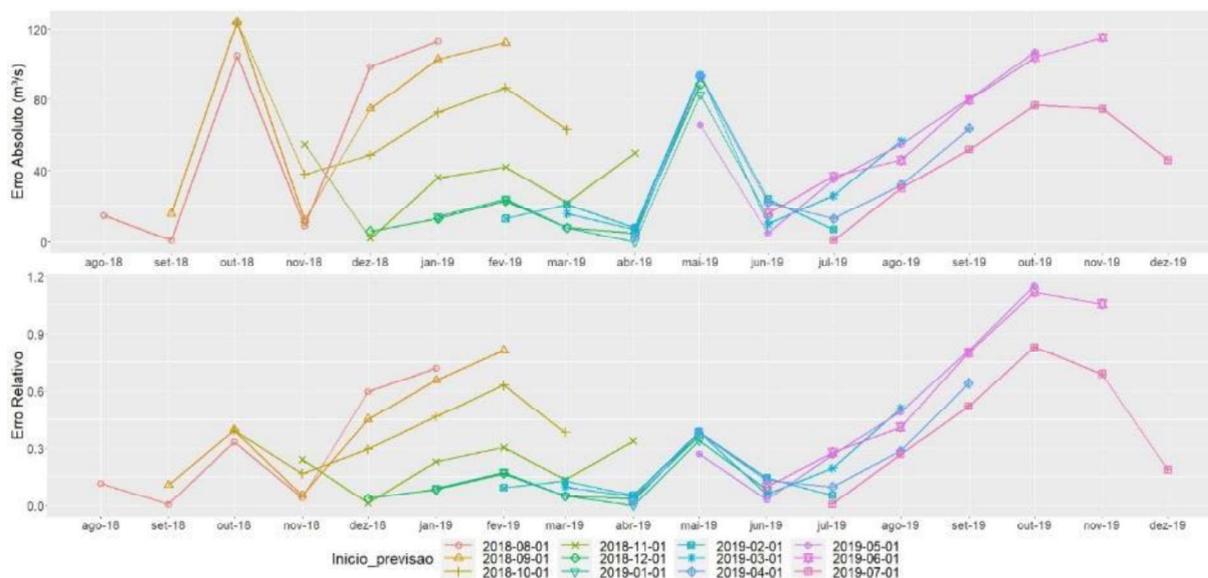


Figura AP.89 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia do rio Iguatemi, mês a mês.

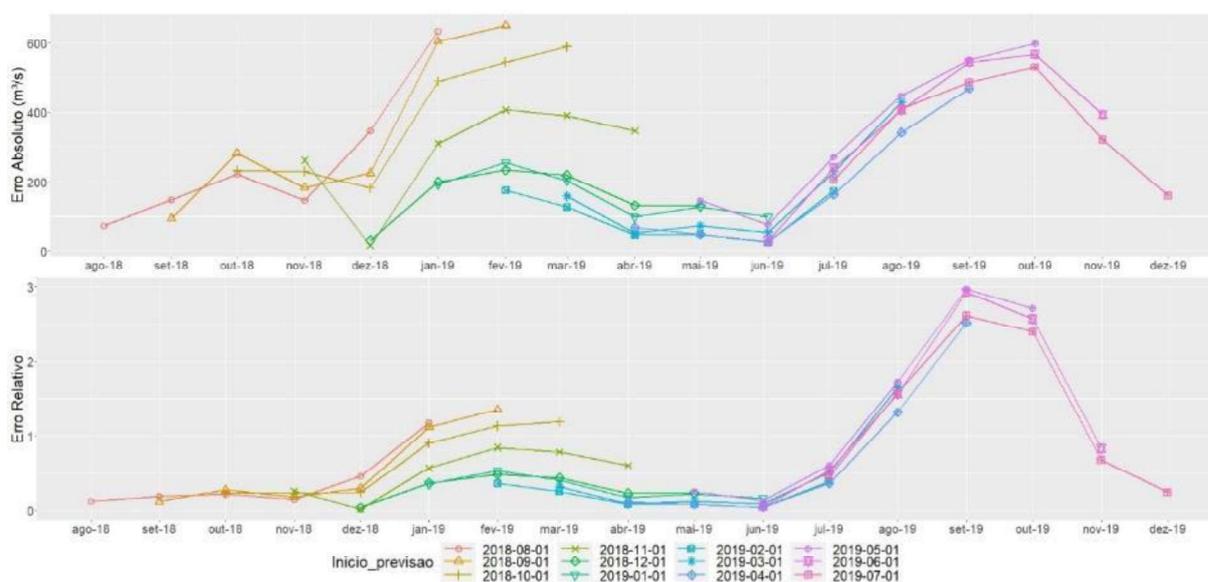


Figura AP.90 - Evolução do desempenho da mediana de cada série de previsão probabilística da sub-bacia “não-monitorada”, mês a mês.