

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÕES DE VAZÕES MENSAIS PARA USINAS DO
SISTEMA HIDROELÉTRICO BRASILEIRO
UTILIZANDO MÉTODOS ESTOCÁSTICOS E
INFORMAÇÕES CLIMÁTICAS**

THIAGO LAPPICY LEMOS GOMES

ORIENTADOR: CARLOS HENRIQUE RIBEIRO LIMA

**DISSERTAÇÃO DE MESTRADO EM TECNOLOGIA AMBIENTAL
E RECURSOS HÍDRICOS**

PUBLICAÇÃO: PTARH.DM – 252/2023

BRASÍLIA/DF: JULHO – 2023.

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL**

**PREVISÕES DE VAZÕES MENSAIS PARA USINAS DO SISTEMA
HIDROELÉTRICO BRASILEIRO UTILIZANDO MÉTODOS
ESTOCÁSTICOS E INFORMAÇÕES CLIMÁTICAS**

THIAGO LAPPICY LEMOS GOMES

**DISSERTAÇÃO SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE
TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU
DE MESTRE EM TECNOLOGIA AMBIENTAL E RECURSOS
HÍDRICOS.**

APROVADA POR:

**Prof. Carlos Henrique Ribeiro Lima, PhD (ENC-UnB)
(Orientador)**

**Prof. Dirceu Silveira Reis Junior, PhD (ENC-UnB)
(Examinador Interno)**

**Prof. Wilson dos Santos Fernandes, PhD (UFMG)
(Examinador Externo)**

BRASÍLIA/DF, 24 DE JULHO DE 2023

FICHA CATALOGRÁFICA

GOMES, THIAGO LAPPICY LEMOS

Previsões de vazões mensais para usinas do sistema hidroelétrico brasileiro utilizando métodos estocásticos e informações climáticas [Distrito Federal] 2023.

xv, 140 p., 210 x 297 mm (ENC/FT/UnB, Mestre, Tecnologia Ambiental e Recursos Hídricos, 2023).

Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

1. Previsões de vazões mensais

2. Hidroelétricas

3. Métodos estocásticos

4. Informações climáticas

I. ENC/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

GOMES, T. L. L. (2023). Previsões de vazões mensais para usinas do sistema hidroelétrico brasileiro utilizando métodos estocásticos e informações climáticas. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DM-252/2023, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 140 p.

CESSÃO DE DIREITOS

AUTOR: Thiago Lappicy Lemos Gomes

TÍTULO: Previsões de vazões mensais para usinas do sistema hidroelétrico brasileiro utilizando métodos estocásticos e informações climáticas.

GRAU: Mestre

ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Thiago Lappicy Lemos Gomes

SQS 310 Bloco D, Brasília.

AGRADECIMENTOS

Obrigado a todos que tiveram alguma participação na minha trajetória dos últimos 3 anos e meio. O COVID-19 foi um momento extremamente difícil para qualquer um e graças a todos aqueles que cito aqui (dentre outros), se tornou um pouco menos difícil de lidar.



Ao meu orientador, prof. Carlos Lima pela orientação e ajuda durante o meu mestrado. Em realidade, devo muito a todos professores do PTARH que tiveram um impacto gigantesco na minha formação. Um enfoque em especial aos professores Dirceu Reis, Sergio Koide e a Rejane Cicerelli que contribuíram enormemente com disciplinas durante o mestrado assim como diversas trocas fora da sala de aula.

Agradeço a equipe do CDS, que me recebeu de braços abertos no grupo de pesquisa e me fizeram sentir sempre muito bem vindo – obrigado Saito, Romero, Samira, Ana Cabral, Babete e Júlia. Cresci enormemente nos últimos anos com todos. Um grande abraço para o Saulo, Teresa, Pufal e Abdala da COHID (ANA). Tive um desenvolvimento profissional tremendo trabalhando com vocês. Agradeço também ao Felipe Treistman, do ONS, por ter dado diversos direcionamentos importantes durante o seminário 1, assim como por me convidar para participar do GT do ONS e participar de reuniões e projetos interessantíssimos.

Deixo aqui também um agradecimento em especial a todos amigos que fiz durante o mestrado e aqueles que levo comigo de outros momentos da minha vida. Um carinho especial para o US!, Diretoria, Agregos (+ Hand) e a minha turma do PTARH (2020), assim como outros colegas de outros anos do mesmo programa.

Não posso deixar de agradecer a minha família, por todos momentos que tivemos nos últimos anos relacionados ao mestrado ou não. Por último, agradeço enormemente a minha namorada e companheira de vida, que teve muita paciência durante todos esses anos e que me apoiou pelo longo tempo que tive que dedicar ao mestrado. Te amo!

RESUMO

Esse trabalho busca avançar nas previsões de vazões mensais ao sistema hidroelétrico brasileiro, incorporando informações climática aos modelos periódicos atualmente em uso pelo operador nacional do sistema (ONS). A informação climática foi incluída como variáveis exógenas nos modelos de previsões (PARX e RIDGE) a partir do uso de índices climáticos. Os indicadores climáticos utilizados são em função da temperatura da superfície do mar do Oceano Atlântico Sul (SST2) e do Pacífico Central (NINO3) e dos padrões de vento sobre o Sudeste Brasileiro (U1).

A regressão *ridge* foi uma forma de incluir esses preditores climáticos nas previsões. Esse é um método de regularização (L2), que é capaz de introduzir um pouco de viés no modelo como tentativa de reduzir a variância das previsões. Já o PARX é um modelo periódico autorregressivo (do tipo PAR) que consegue acoplar variáveis exógenas, com seus coeficientes sendo calculados, neste trabalho, pelo método dos mínimos quadrados.

A partir das métricas de desempenho NSE e KGE para os diferentes meses e horizontes de previsão (entre 1 e 6 meses a frente), observou-se ganhos relevantes a partir da inclusão da informação climática. Os valores de NSE, KGE, α , r , β_{NSE} e β_{KGE} apresentaram, respectivamente, ganhos em até 68%, 79%, 90%, 71%, 81% e 82% das UHEs quando agrupadas para cada mês. Na espacialização, nota-se um melhor ganho do uso dos preditores climáticos nas regiões Norte e Sul do país, mostrando uma dificuldade nas previsões mais centrais e do Nordeste.

Os ganhos são menores quando agrupando as UHEs individuais em reservatórios equivalentes de energia (REE) e subsistemas. Ao realizar esse agrupamento, fica ainda mais perceptível o efeito que cada indicador climático tem nas previsões, com padrões similares se mantendo (Norte e Sul tendo as melhores previsões e os subsistemas Nordeste e Sudeste/Centro-Oeste tendo ganhos em menos situações). Ainda assim, o subsistema Nordeste apresentou ganho em 49% dos cenários (72 cenários sendo das previsões de até 6 meses a frente de cada um dos 12 meses). No sistema Norte o ganho atingiu 78% dos cenários avaliados.

ABSTRACT

This work aims on advancing the streamflow monthly forecasts for the Brazilian hydroelectric system, by incorporating climatic information to the periodic models currently used by the national operator (ONS). The climatic information was included as exogenous variables in the forecasting models (PARX and RIDGE) with climatic indexes. These indicators are related to the sea surface temperature (SST) for part of the Atlantic Ocean (SST2) and part of the Pacific Ocean (NINO3) as well as the pattern of the alisium winds on the southeast of Brazil (U1).

The ridge regression is one option used to include the climatic predictors into the forecasts. This is a L2 regularization method that introduces some bias in an attempt to reduce the variance of the forecasts (known as bias-variance tradeoff). The PARX is a periodic autoregressive model (PAR type) that can use exogenous variables, with its coefficients being calculated, in this work, by the least square method.

With performance metrics such as the NSE and KGE for different months and lead times (1 to 6 months ahead), it was observed relevant gains with the addition of the climatic information. The values for NSE, KGE, α , r , β_{NSE} and β_{KGE} where up to, respectively, 68%, 79%, 90%, 71%, 81% and 82% of the individual hydropower plants when grouped by each month. During the spatialization, there was a bigger gain for the use of climatic predictors in the Northern and Southern parts of Brazil, showing some difficulties for the forecast in more central areas, as well as for the Northeastern region.

Although the gains were lower when grouping individual hydropower plants into equivalent energy reservoirs (REE) and subsystems, they made more perceptible the effect that each climatic indicator has in the forecasts. There were visible patterns, with the South and the North having the better forecast – the latter having a gain of 78% in the scenarios evaluated. Moreover, the Brazilian Northeast subsystem, which had the lowest gains when using climatic predictors, showed a gain in 49% of the scenarios (from a total of 72 for forecasting up to 6 months ahead for each of the 12 months), which is still significant.

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	4
2.1 OBJETIVO GERAL	4
2.2 OBJETIVOS ESPECÍFICOS	4
3. FUNDAMENTAÇÃO TEÓRICA E REVISÃO DE LITERATURA	5
3.1 SÉRIES TEMPORAIS, MODELOS ESTOCÁSTICOS E RESÍDUOS	5
3.1.1 Modelos AR, MA, ARMA, ARIMA e SARIMA	9
3.1.1.1 Modelos AR	9
3.1.1.2 Modelos MA	11
3.1.1.3 Modelos ARMA.....	12
3.1.1.4 Modelos ARIMA	13
3.1.1.5 Modelos SARIMA	13
3.1.1.6 Estimação dos parâmetros.....	14
3.1.2 Modelos PAR, PARMA e PARX	15
3.1.2.1 Modelos PAR.....	15
3.1.2.2 Modelos PARMA	16
3.1.2.3 Modelos PARX	17
3.1.3 Regressão <i>ridge</i>	18
3.1.4 Ruídos, Resíduos e Erros	18
3.1.5 Seleção do Modelo	21
3.1.6 Avaliação do Modelo	22
3.2 SISTEMA HIDROELÉTRICO BRASILEIRO	30
3.2.1 SIN e o ONS	31
3.2.2 Previsões no SIN	36
3.2.3 Reservatório Equivalente de Energia (REE)	38

3.3 VARIÁVEIS EXÓGENAS	40
3.3.1 Eventos Climáticos de Larga Escala	41
3.3.2 Uso de variáveis climáticas para previsões de vazões na literatura	42
4. METODOLOGIA.....	51
4.1 DADOS UTILIZADOS.....	55
4.1.1 Série histórica das vazões naturalizadas e energia afluyente.....	55
4.1.2 Preditores climáticos escolhidos e suas séries históricas	57
4.2 MODELOS UTILIZADOS	59
4.3 AVALIAÇÃO DOS MODELOS.....	60
5. ÁREA DE ESTUDO	63
6. RESULTADOS	66
6.1 ANÁLISE EXPLORATÓRIA DAS UHEs	66
6.2 VARIÁVEIS CLIMÁTICAS.....	69
6.3 QUALIDADE DAS PREVISÕES.....	73
6.3.1 Avaliação dos modelos por mês e horizonte de previsão (<i>lead</i>)	74
6.3.2 Análise espacial dos ganhos dos modelos climáticos.....	81
6.3.3 Ganho quantitativo dos modelos	84
6.3.4 Ganho de cada indicador climático	90
6.4 REEs	92
6.5 SUBSISTEMAS.....	96
6.6 COMENTÁRIOS GERAIS	101
7. CONCLUSÕES.....	102
REFERÊNCIAS BIBLIOGRÁFICAS	105
APÊNDICE A – DETALHES DOS REES E SUBSISTEMAS	114
APÊNDICE B – CONFIGURAÇÃO DO SIN	121
APÊNDICE C – PLANO 3D DO GANHO CLIMÁTICO DOS MODELOS.....	122

APÊNDICE D – RESULTADOS PELO CONCEITO DE REE.....	124
APÊNDICE E – RESULTADOS PELO CONCEITO DE SUBSISTEMAS	127

LISTA DE FIGURAS

Figura 3.1 Representação gráfica de um processo estocástico (Serinaldi et al., 2018 – tradução do autor).....	6
Figura 3.2 Gráficos de autocorrelação (ACF) para quatro modelos.....	8
Figura 3.3 Gráficos de autocorrelação parcial (PACF) para quatro modelos	8
Figura 3.4 Demonstração gráfica da distância multicritério (DM)	25
Figura 3.5 Matriz Elétrica e Energética do Brasil no ano de 2020.....	30
Figura 3.6 SIN com usinas hidroelétricas (triângulos) e térmicas, representadas por quadrados (modificado – SINDAT, 2021)	32
Figura 3.7 Modelos Hidrológicos e para Planejamento da Operação do SIN (Costa et al., 2007).....	34
Figura 3.8 Árvore de decisão sobre a operação de um sistema hidrotérmico	35
Figura 3.9 Os REEs e os subsistemas do SIN (MME, 2017)	39
Figura 3.10 Nuvem de palavras referentes aos artigos da Tabela 3.4	45
Figura 4.1 Fluxograma geral da metodologia utilizada no presente trabalho	51
Figura 4.2 Fluxograma da rotina criada em R seguindo a metodologia deste trabalho .	53
Figura 4.3 Valores de MWmed para os quatro subsistemas em escala mensal (Lappicy et al., 2021)	57
Figura 4.4 Localizações das variáveis climáticas usadas (modificado – Lima e Lall, 2010).....	58
Figura 5.1 Reservatórios com as bacias hidrográficas do Brasil.....	63
Figura 5.2 UHEs com as bacias hidrográficas do Brasil por subsistema	64
Figura 5.3 UHEs com as bacias hidrográficas do Brasil por REE	64
Figura 6.1 Estacionariedade das UHEs pelo teste do KPSS.....	67
Figura 6.2 Relação entre a Q_{95} mensal e a Q histórica por UHE e subsistema	68
Figura 6.3 Relação entre a Q_{95} mensal e a Q histórica por UHE e REE	69
Figura 6.4 Correlação Cruzada entre as vazões e os preditores climáticos.....	71
Figura 6.5 Correlação das variáveis climáticas escolhidas e defasagens t	73
Figura 6.6 Ganho de cada modelo para diferentes meses por UHE	76
Figura 6.7 Ganho de cada modelo para diferentes <i>leads</i> por UHE	78
Figura 6.8 Valor do NSE para cada mês e horizonte de previsão (<i>lead</i>) por UHE	80

Figura 6.9 Valor do KGE para cada mês e horizonte de previsão (<i>lead</i>) por UHE	81
Figura 6.10 Ganho climático (transparência) das UHEs agrupadas por subsistema	83
Figura 6.11 Ganho climático (transparência) das UHEs agrupadas por REE	84
Figura 6.12 Valor das componentes avaliadas para os diferentes modelos usados.....	85
Figura 6.13 Ganho das componentes avaliadas com os modelos climáticos	87
Figura 6.14 Ganho climático (transparência) do uso do preditor U1 nas previsões.....	90
Figura 6.15 Ganho climático (transparência) do uso do preditor SST2 nas previsões...	91
Figura 6.16 Ganho climático (transparência) do uso do preditor U1 nas previsões.....	91
Figura 6.17 Valor do KGE para cada mês e horizonte de previsão (<i>lead</i>) por REE	93
Figura 6.18 Ganho climático dos REEs pelo KGE	94
Figura 6.19 Ganho do uso do preditor U1 nas previsões por REE.....	95
Figura 6.20 Ganho do uso do preditor SST2 nas previsões por REE.....	95
Figura 6.21 Ganho do uso do preditor NINO3 nas previsões por REE.....	96
Figura 6.22 Valor do NSE para cada mês e <i>lead</i> por subsistema	97
Figura 6.23 Valor do KGE para cada mês e <i>lead</i> por subsistema	98
Figura 6.24 Ganho climático dos subsistemas pelo KGE	99
Figura 6.25 Ganho do uso do preditor U1 nas previsões por subsistemas	99
Figura 6.26 Ganho do uso do preditor SST2 nas previsões por subsistemas	100
Figura 6.27 Ganho do uso do preditor NINO3 nas previsões por subsistemas	100
Figura B.1 Configuração do SIN 2023 – 2027	121
Figura C.1 Plano 3D com o a quantidade de UHEs com ganho climático, pelo NSE, de cada mês e <i>lead</i>	122
Figura C.2 Plano 3D com o a quantidade de UHEs com ganho climático, pelo KGE, de cada mês e <i>lead</i>	123
Figura D.1 Ganho de cada modelo para diferentes meses por REE.....	124
Figura D.2 Ganho de cada modelo para diferentes horizontes de previsão (<i>lead</i>) por REE.....	125
Figura D.3 Valor do NSE para cada mês e horizonte de previsão (<i>lead</i>) por REE.....	126
Figura E.1 Ganho de cada modelo para diferentes meses por subsistema	127
Figura E.2 Ganho de cada modelo para diferentes horizontes de previsão (<i>lead</i>) por subsistema.....	128

LISTA DE TABELAS

Tabela 3.1 – Classes do NSE segundo Moriasi et al. (2007) para dados mensais	27
Tabela 3.2 – Modelos de Previsão utilizados no PREVIVAZ	37
Tabela 3.3 – Número de UHEs por REE e Subsistema.....	39
Tabela 3.4 – Revisão da literatura sobre uso de variáveis exógenas em previsões hidrológicas com métodos “tradicionais”	43
Tabela 3.5 – Revisão da literatura sobre <i>ensemble learning</i> aplicado a previsão de vazões	47
Tabela 6.1 – Ganho de cada componente para os modelos climáticos.....	89
Tabela A.1 12 REEs dos 4 Subsistema do SIN	114
Tabela A.2 UHEs do REE Amazonas (Subsistema Norte)	114
Tabela A.3 UHEs do REE Belo Monte (Subsistema Norte)	114
Tabela A.4 UHEs do REE Norte (Subsistema Norte)	114
Tabela A.5 UHEs do REE Nordeste (Subsistema Nordeste)	115
Tabela A.6 UHEs do REE Iguaçu (Subsistema Sul)	115
Tabela A.7 UHEs do REE Sul (Subsistema Sul).....	116
Tabela A.8 UHEs do REE Itaipu (Subsistema Sudeste/Centro-Oeste).....	116
Tabela A.9 UHEs do REE Madeira (Subsistema Sudeste/Centro-Oeste).....	116
Tabela A.10 UHEs do REE Paraná (Subsistema Sudeste/Centro-Oeste)	117
Tabela A.11 UHEs do REE Paranapanema (Subsistema Sudeste/Centro-Oeste).....	118
Tabela A.12 UHEs do REE Sudeste (Subsistema Sudeste/Centro-Oeste).....	119
Tabela A. 13 UHEs do REE Teles Pires (Subsistema Sudeste/Centro-Oeste).....	120

LISTA DE EQUAÇÕES

[Eq. 3.1]	10
[Eq. 3.2]	10
[Eq. 3.3]	10
[Eq. 3.4]	11
[Eq. 3.5]	11
[Eq. 3.6]	12
[Eq. 3.7]	13
[Eq. 3.8]	13
[Eq. 3.9]	14
[Eq. 3.10]	14
[Eq. 3.11]	15
[Eq. 3.12]	16
[Eq. 3.13]	16
[Eq. 3.14]	16
[Eq. 3.15]	16
[Eq. 3.15]	17
[Eq. 3.17]	18
[Eq. 3.18]	19
[Eq. 3.19]	22
[Eq. 3.20]	23
[Eq. 3.21]	24
[Eq. 3.22]	24
[Eq. 3.23]	25
[Eq. 3.24]	28
[Eq. 3.25]	28
[Eq. 3.26]	28
[Eq. 3.27]	28
[Eq. 3.28]	28
[Eq. 4.1]	56

LISTA DE ABREVIACES

ACF.....	<i>Auto Correlation Function</i>
AIC.....	<i>Akaike Information Criteria</i>
AICc.....	<i>Akaike Information Criteria Corrected</i>
AMO.....	<i>Atlantic Multidecadal Oscillation</i>
ANELL.....	Agncia Nacional de Energia Eltrica
ANN.....	<i>Artificial Neural Networks</i>
AR.....	<i>Autoregressive</i>
ARIMA.....	<i>Autoregressive Integrated Moving Average</i>
ARMA.....	<i>Autoregressive Moving Average</i>
CEPEL.....	Centro de Pesquisas de Energia Eltrica
CNRH.....	Conselho Nacional de Recursos Hdricos
DT.....	<i>Decision Trees</i>
ENA.....	Energia Natural Afluente
ENSO.....	<i>El Nio South Oscillation</i>
ETS.....	<i>Error, Trend and Seasonality</i>
GCV.....	<i>Generalized Cross Validation</i>
GEE.....	Gases do Efeito Estufa
iid.....	Independente e Identicamente Distribuído
KGE.....	<i>Kling-Gupta efficiency coefficient</i>
KPSS.....	Kwiatkowski–Phillips–Schmidt–Shin
m ³	metro cbico
MA.....	<i>Moving Average</i>
MAD.....	<i>Mean Absolute Deviation</i>
MAE.....	<i>Mean Absolute Error</i>
MAPE.....	<i>Mean Absolute Percentage Error</i>
ML.....	<i>Machine Learning</i>
MW.....	Mega Watt
NSE.....	<i>Nash Sutcliffe Efficiency Coefficient</i>
NSElog.....	log do NSE
ONS.....	Operador Nacional do Sistema Eltrico
OOB.....	<i>Out Of Bag Error</i>
PACF.....	<i>Partial Auto Correlation Function</i>

PAR.....	<i>Periodic Autoregressive</i>
PARMA.....	<i>Periodic Autoregressive Moving Average</i>
PARX.....	<i>Periodic Autoregressive Exogenous</i>
PDO.....	<i>Pacific Decadal Oscillation</i>
REE.....	Reservatório Equivalente de Energia
RF.....	<i>Random Forrests</i>
RMSE.....	<i>Root Mean Square Error</i>
s.....	segundos
SARIMA.....	<i>Seasonal Autoregressive Integrated Moving Average</i>
SIN.....	Sistema Interligado Nacional
SMAP.....	<i>Soil Moisture Accounting Procedure</i>
STL.....	<i>Seasonal Trend decomposition using LOESS</i>
SVM.....	<i>Support Vector Machines</i>
TSO.....	Temperatura da Superfície do Oceano
UHE.....	Usina Hidroelétrica

1. INTRODUÇÃO

A matriz elétrica Brasileira é fortemente dependente das usinas hidroelétricas, sendo responsável por aproximadamente 64% dessa matriz (IEA, 2020; MME, 2020). A operação desse sistema é extremamente complexa e se baseia fortemente em previsões das vazões futuras em diferentes escalas temporais (diária, semanal, mensal e anual). Dessa forma, uma melhor previsão das vazões se mostra essencial para a operação do sistema brasileiro.

Existem diversos modelos utilizados hoje pelo Operador Nacional do Sistema elétrico (ONS) para fazer as previsões nas hidroelétricas pertencentes ao Sistema Nacional Interligado (SIN). Na escala mensal, destacam-se os modelos estocásticos autoregressivos, como o PREVIVAZM e o GEVAZP, dentre outros (Maceira et al., 2018; CEPEL, 2019; CEPEL, 2018; CEPEL, 2015; Maceira et al., 2008; Costa et al., 2007). Tais modelos buscam definir o processo estocástico gerador da série histórica observada baseando-se apenas na própria série histórica e não levando em conta outros fatores ou variáveis externas.

Há diversos estudos na literatura que discutem sobre o ganho em utilizar diferentes variáveis exógenas para auxiliar nas previsões de vazões. Apesar do uso de previsões numéricas de chuva serem amplamente utilizadas para previsões em escalas diárias ou semanais, elas são deficientes na escala mensal. Assim, muitos trabalhos de previsões mensais propõem o uso de indicadores de eventos climáticos de larga escala como preditores climáticos (Pham et al., 2021; Li et al., 2020; Moradi et al., 2020; Silveira et al., 2017; Oliveira e Lima, 2016; Schik et al., 2016; Li et al., 2010; Lima e Lall, 2010b; Lima e Lall, 2010a).

Dessa forma, uma maneira de fazer as previsões mensais de maneira similar ao feito hoje pelo ONS (modelos autorregressivos do tipo PAR), é utilizando modelos periódicos autorregressivos com variáveis exógenas (PARX). Este tipo de modelo é capaz de acoplar tais variáveis climáticas e consegue, portanto, incorporar o ganho comentado na literatura de se utilizar tais variáveis, assim como mantém equacionamentos similares aos

utilizados hoje – mantendo então a fácil interpretação dos resultados e possível incorporação desses modelos específicos (PARX) ao PREVIVAZM – usado hoje.

Diversos trabalhos também comentam sobre o possível ganho em utilizar modelos mais complexos como os de aprendizado de máquina (*machine learning*) para explicar melhor essa relação entre clima e vazões (Pham et al., 2021; Li et al., 2020; Ribeiro et al., 2020; Fu et al., 2019; Botsis et al, 2019; Schick et al., 2016; Erdal e Karakurt, 2013; Karakurt et al., 2013; Li et al., 2010; Anctil e Lauzon, 2004.). Nesse contexto, são comuns o uso de métodos de agrupamento, ou *ensemble*, como *bagging* e *boosting*. Apesar de poderem aparentar como promissores, esses métodos são pouco interpretáveis (também conhecidos como caixa preta ou *black-box*) o que representa dificuldades para seu uso por tomadores de decisões (se torna necessário uma confiança extrema no modelo e modeladores).

Considerando que a inclusão de um número elevado de preditores em modelos estocásticos pode levar a uma perda de performance, em particular quando os preditores estão correlacionados, pode-se fazer a escolha desses preditores pela regressão *ridge*. Este é um método de aprendizado de máquina interpretável, tornando-se uma opção mais viável em relação aos métodos do tipo “caixa preta”. Esse modelo *ridge* não apenas seleciona quais preditores devem ser utilizados, mas também define o grau de influência de cada um deles (Berk, 2020; James et al., 2013).

O presente trabalho busca contribuir com o aperfeiçoamento das previsões mensais de vazões a partir da incorporação de informações climáticas em métodos estocásticos autoregressivos. Foram propostos 3 indicadores climáticos de larga escala para isso: os ventos alísios em parte do Sudeste Brasileiro (U1) e a temperatura da superfície do oceano em parte do Atlântico (SST2) e em parte do oceano pacífico (NINO3). Esses preditores já se mostraram capazes em conseguir um ganho nas previsões de vazões em hidroelétricas pertencentes ao SIN (Oliveira e Lima, 2016; Lima et al., 2010a; Lima et al., 2010b).

A presente dissertação está dividida em 6 capítulos, contando com essa introdução. O segundo capítulo (II) é uma breve descrição do objetivo geral do trabalho acompanhando pelos objetivos específicos em maiores detalhes. O capítulo 3 (III) traz o referencial teórico necessário para este trabalho juntamente com uma revisão da literatura existente

acerca do tema. O principal foco nesta seção é sobre os modelos estocásticos assim como as métricas de avaliação utilizadas (NSE e KGE). O quarto capítulo (IV) descreve a metodologia proposta e empregada nessa dissertação, necessária para atingir os objetivos propostos, juntamente com uma descrição dos dados utilizados (as usinas hidroelétricas, a série histórica de vazões e os indicadores climáticos). O capítulo 5 (V) traz os principais resultados atingidos, avaliando a quantidade de cenários em que há ganho na previsão com o uso dos indicadores climáticos juntamente com uma espacialização dele, a magnitude desse ganho e o impacto de cada um dos preditores utilizados. Esses resultados foram feitos a nível das hidroelétricas individuais (UHEs) como também para os reservatórios equivalentes de energia (REE) e subsistemas do sistema interligado nacional (SIN) e são comentados e discutidos no mesmo capítulo (V). O último capítulo, VI, resume as principais conclusões do trabalho, propondo possíveis caminhos para trabalhos futuros conseguirem complementar o que foi feito aqui.

2. OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo geral do presente trabalho é aperfeiçoar as previsões mensais de vazões para as usinas hidroelétricas pertencentes ao Sistema Interligado Nacional (SIN) a partir do uso de modelos estocásticos periódicos autoregressivos e utilizando informações climáticas de larga escala.

2.2 OBJETIVOS ESPECÍFICOS

- Fazer uma análise exploratória das usinas despachadas pelo ONS e seus dados disponíveis verificando a estacionariedade e comportamento sazonal das séries mensais naturalizadas incrementais assim como analisar a correlação das variáveis climáticas escolhidas com as vazões e a correlação entre elas próprias;
- Avaliar o ganho (qualitativo e quantitativo) nas previsões a partir da inclusão de variáveis climáticas no modelo periódico autorregressivo (PARX), similares aos utilizados atualmente pelo setor, assim como no modelo RIDGE proposto;
- Verificar espacialmente onde cada indicador é mais dominante, avaliando isso nas UHEs individuais, nos REEs e nos subsistemas utilizados atualmente pelo ONS.

3. FUNDAMENTAÇÃO TEÓRICA E REVISÃO DE LITERATURA

3.1 SÉRIES TEMPORAIS, MODELOS ESTOCÁSTICOS E RESÍDUOS

Séries nas quais os dados são obtidos sucessivamente e durante determinado tempo são denominadas de séries temporais, podendo então ser utilizadas tanto para dados obtidos de maneira discreta ou contínua. Elas são amplamente utilizadas em diversas áreas de conhecimento, porém, os métodos utilizados para descrever elas são os mesmos independente do assunto – podendo ser sobre variáveis climatológicas, biológicas, econômicas ou outras. Existem diversas análises possíveis de serem feitas em uma série temporal como correlações e previsões, essa última sendo chave no presente trabalho.

Usualmente, para descrever séries temporais, usa-se números inteiros como índice para indicar a ordem de coleta desses dados. Além disso, é comum a utilização de letras maiúsculas para denominar as variáveis aleatórias e letras minúsculas para denominar observações/dados referentes a essa variável. Por exemplo, adotando uma variável aleatória Z , pode-se chamar um dado coletado no instante i de z_i . Assim, assume-se que z_1 ocorre de maneira anterior a z_2 e assim por diante. É comum a utilização da notação “ $\{Z_t\}$ ” para descrever um processo estocástico (Shumway e Stoffer, 2019).

Processos estocásticos são o oposto de processos determinísticos ao passo de que mesmo conhecendo as condições iniciais de um sistema, um processo estocástico pode evoluir de diversas maneiras distintas, existindo então aleatoriedade e, portanto, indeterminação e incerteza sempre ligadas a esse processo. Existe uma investida na literatura em utilizar métodos estocásticos para descrever séries temporais e fazer previsões nelas. Isso significa explicar o valor da variável em um tempo t a partir apenas dos valores observados anteriores a t (Shumway e Stoffer, 2019; Box e Jenkins, 1976). Para isso, tenta-se definir um modelo a partir dos dados observados, que consiga representar o mecanismo estocástico criador da série observada em questão.

Usualmente, parte dessa característica aleatória pode ser descrita por um ruído branco, denominado por $\{\varepsilon_t\}$. Esse é um processo iid (independente e identicamente distribuído)

com média zero e variância constante. Comumente o ruído branco é dito como um processo que segue uma distribuição normal apesar de poder seguir diferentes distribuições probabilísticas (Hipel e McLeod, 1994).

Processos estocásticos, em geral, podem ser decompostos em três componentes: tendência, sazonalidade e ruído (comentado anteriormente). Além disso, existem algumas características importantes acerca de processos estocásticos como estacionariedade (se suas características, como média e variância, se mantêm no tempo) e ergodicidade – se é possível, a partir da amostra, fazer uma inferência das características populacionais por elas convergirem a um valor à medida que o número de observações aumenta (Hipel e McLeod, 1994). A Figura 3.1 mostra uma representação gráfica desse tipo de processo.




Figura 3.1 Representação gráfica de um processo estocástico (Serinaldi et al., 2018 – tradução do autor)

Um ponto crucial de modelagens em geral, é que a série histórica observada é apenas uma amostra de uma população de dados. Essas observações existem em apenas uma parte do “espaço paramétrico”, tempo t , e para uma amostra específica, ou um “espaço de evento”. De tal modo, não se tem acesso a toda a série histórica existente (referente ao passado) ou a série de acontecimentos futuros, apenas um pedaço dela referente ao tempo t medido. Já o espaço de evento representa as diferentes possíveis realizações de um processo

estocástico, ou seja, as possíveis séries que poderiam ter ocorrido originadas do mesmo mecanismo estocástico. Isso é mostrado visualmente pela Figura 3.1.

Na Figura 3.1 é possível notar que a série histórica observada está com coloração roxa e é representada por $\hat{f}_{\text{obs}}(x)$. Ela é apenas uma realização possível de um mecanismo estocástico. As outras séries $\hat{f}_1(x)$, $\hat{f}_j(x)$, $\hat{f}_k(x)$ e $\hat{f}_l(x)$ são todas oriundas do mesmo mecanismo estocástico e, apesar de não terem sido realizadas, poderiam ter se sucedido. Portanto, é necessária a suposição de um processo ergódico para poder inferir características de uma amostra suficientemente grande para a população, e assim, poder fazer previsões para cenários futuros (Serinaldi et al., 2018).

Dois gráficos informativos na análise de processos estocásticos são os gráficos, ou correlogramas, ACF (Função de Autocorrelação) e PACF (Função de Autocorrelação Parcial), sendo definidos aqui e estando presentes na Figura 3.2 e na Figura 3.3 a seguir. Nelas estão demonstrados quatro diferentes tipos de modelos. Esses modelos autorregressivos são explicados em maiores detalhes na seção seguinte (3.1.1 Modelos AR, MA, ARMA, ARIMA e SARIMA).

Em ambas as figuras, existem quatro modelos, com o primeiro sendo um ruído branco definido como uma série de valores com média zero e variância constante. O segundo modelo é autoregressivo de ordem 1, “AR(1)”, o terceiro modelo é um autorregressivo de ordem 3, ou “AR(3)”, com 2 coeficientes negativos e o último modelo contém uma série não estacionária, dada pela soma cumulativa do ruído branco proposto – sendo então um passeio aleatório não estacionário. Os modelos autorregressivos AR(1) e AR(3) são estacionários. As linhas azuis pontilhadas nas figuras representam um intervalo onde o valor do eixo-y é significativamente diferente de zero com nível de significância de 95%.

O correlograma ACF (Figura 3.2) se resume em plotar os valores da função de autocorrelação $\rho(h)$ contra h , com h sendo a defasagem de um processo com autocovariância $\gamma(h) = \gamma(t + h, t)$, para $h = 1, 2, \dots$. Dessa forma, o ACF mede a relação linear entre valores de uma variável defasada no tempo em uma série temporal (Hyndman e Athanasopoulos, 2021). Nota-se que um modelo autorregressivo decai rapidamente para 0, enquanto um modelo não estacionário possui um decaimento lento. Além disso, o sinal

negativo nos coeficientes do modelo AR(3) apenas altera o sinal da autocorrelação, porém ela se mantém presente e se comporta similar ao outro modelo AR(1).

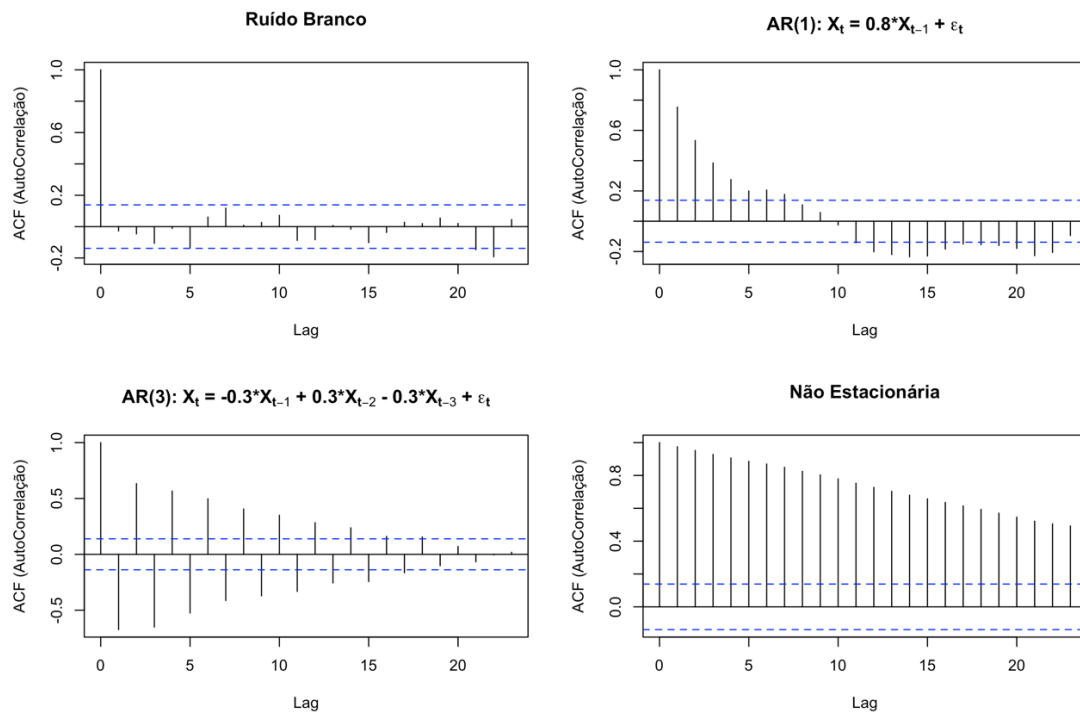


Figura 3.2 Gráficos de autocorrelação (ACF) para quatro modelos

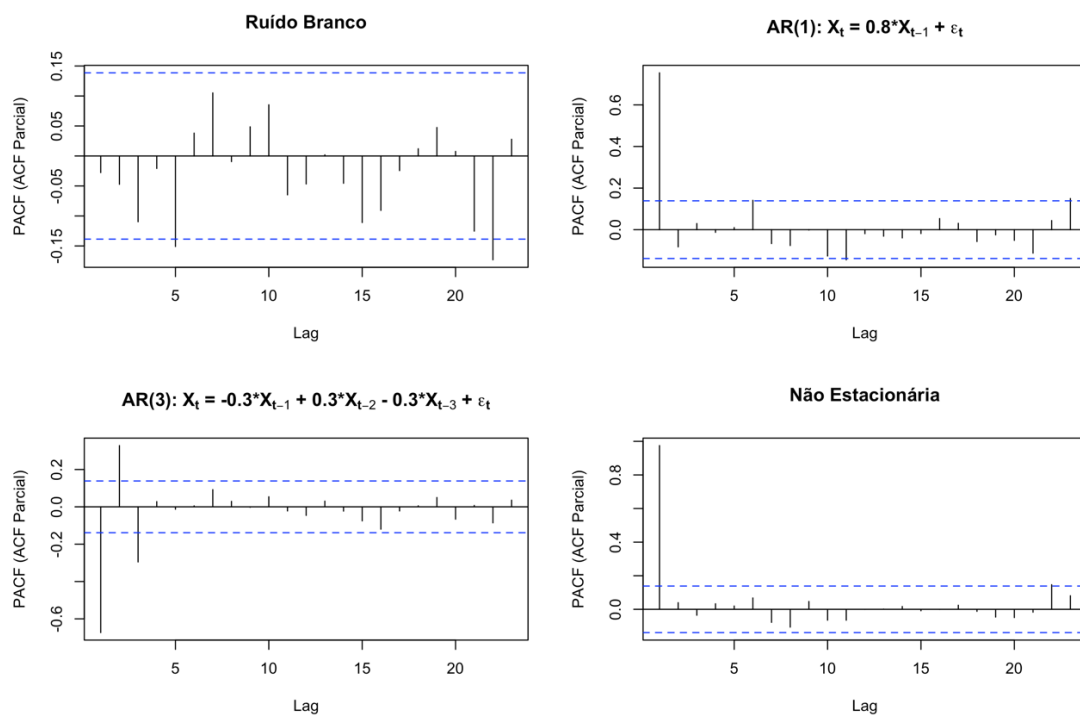


Figura 3.3 Gráficos de autocorrelação parcial (PACF) para quatro modelos

O PACF (Figura 3.3) avalia a relação entre as variáveis Z_t e Z_{t-k} após a retirada do efeito da defasagem (*lag*). Cada autocorrelação parcial pode ser estimada usando os coeficientes de um processo $AR(p)$ estacionário para os diferentes valores de p , medindo o excesso de correlação não levado em conta no modelo $AR(p - 1)$ (Hyndman e Athanasopoulos, 2021). A estimação desses coeficientes é melhor detalhada em uma seção posterior (3.1.1.6 Estimação dos parâmetros). Nota-se que para modelos autorregressivos, o PACF tende a zero (se encontra dentro das linhas azuis) após a ordem do modelo, assim um $AR(1)$ tende a zero a partir de seu 2º valor e o $AR(3)$ tende a zero a partir de seu 4º valor.

Ambos os gráficos, de autocorrelação (ACF) juntamente com o de autocorrelação parcial (PACF) podem auxiliar para determinar a ordem dos processos da família SARIMA explicados na seção seguinte (3.1.1 Modelos AR, MA, ARMA, ARIMA e SARIMA). Porém isso é difícil de ser realizado de uma maneira automática, para tal feito é necessário a utilização de testes estatísticos específicos que possam avaliar a ordem dos modelos autorregressivos.

As duas figuras também são úteis na análise dos resíduos dos modelos. Dado que $\{X_i\}$ é um processo iid com variância finita, então o estimador da autocorrelação amostral de ordem h , $\hat{\rho}(h)$, segue distribuição normal com média zero e variância igual a $\frac{1}{n}$. Caso a estimativa deste estimador, $\hat{\rho}(h)$, esteja fora do intervalo $[0 \pm \frac{2}{\sqrt{n}}]$ então o próprio $\rho(h)$ é significativamente diferente de zero com nível de significância de 95% (Hyndman e Athanasopoulos, 2021). Isso é utilizado nos gráficos ACF e PACF nas Figuras 3.2 e 3.3 estando como uma linha azul pontilhada.

3.1.1 Modelos AR, MA, ARMA, ARIMA e SARIMA

3.1.1.1 Modelos AR

Modelos $AR(p)$ (Box e Jenkins, 1976), também denominados autoregressivos de ordem p , definem um tipo de modelo estocástico e, na forma apresentada, são aplicáveis a séries estacionárias (variância e esperança da variável constantes e função de autocovariâncias depende apenas de uma defasagem h - não dependendo do tempo t). Esses processos

dependem apenas dos valores anteriores da série temporal, como descrito pela forma genérica disposta na equação 3.1.

Nela, Φ_p é denominado de polinômio autoregressivo de ordem p e está matematicamente descrito na equação 3.2 e B é um operador de retardo, descrito na equação 3.3 abaixo. Z_t é a variável de interesse, com $\tilde{Z}_t = Z_t - \mu$ (variação de Z ao redor da média), e $\{\varepsilon_t\}$ é um ruído branco com média zero e variância constante. O operador de retardo, B , que vem do inglês *backshift*, as vezes também é chamado de *lag* na literatura e pode ser simbolizado pela letra L ao invés de B (Hyndman e Athanasopoulos, 2021). É possível utilizar variações de \tilde{Z}_t também, existindo no sistema elétrico brasileiro, por exemplo, o modelo PREVIVAZ que faz uso de $\tilde{Z}_t = \frac{Z_t - \mu_a}{\sigma_a}$, com μ_a e σ_a sendo, respectivamente, a média o desvio padrão da série observada (CEPEL, 2015).

$$\Phi_p(B) * \tilde{Z}_t = \varepsilon_t \quad [\text{Eq. 3.1}]$$

$$\Phi_p(B) = 1 - \phi_1 * B - \phi_2 * B^2 - \dots - \phi_p * B^p \quad [\text{Eq. 3.2}]$$

$$B^p \tilde{Z}_t = \tilde{Z}_{t-p} \quad [\text{Eq. 3.3}]$$

É comum utilizar algumas restrições para que o modelo seja estacionário. Por exemplo, para um caso AR(1), o coeficiente autoregressivo ϕ_1 deve ser estar, em módulo, dentro do círculo unitário (ser menor do que 1 em módulo). Para valores de p maiores, as relações podem ficar mais complicadas, mas existem pacotes computacionais no R que podem lidar com tais restrições quando utilizando modelos AR(p), como o *fable* (Hyndman e Athanasopoulos, 2021).

O modelo AR(p) possui então $p + 2$ parâmetros para serem estimados a partir da série histórica (esses sendo $\phi_1, \phi_2, \dots, \phi_p, \sigma_\varepsilon^2, \mu$). O modelo é tido como estacionário se o módulo das raízes do polinômio autorregressivo de ordem p , Φ_p , estiver fora do círculo unitário, ou seja, maior do que 1 (Box e Jenkins, 1976). Esse é um fato importante para a estimação da autocovariância e da autocorrelação.

Uma maneira de identificar a ordem do modelo AR(p) é visualmente utilizando os gráficos de ACF e PACF (Figura 3.2 e Figura 3.3). Lembrando que a série deve ser estacionária para utilizar esses modelos, o ACF neles decai de forma amortizada para zero

e o PACF é zero a partir do lag p . Assim, visualmente é possível descrever opções viáveis de p (Shumway e Stoffer, 2019) – estando exemplificadas na Figura 3.2 e Figura 3.3.

3.1.1.2 Modelos MA

Modelos MA(q) (Box e Jenkins, 1976), conhecidos como modelos de média móvel de ordem q , podem ser definidos de uma forma abrangente como nas equações 3.4 e 3.5. Esses modelos definem uma variável Z_t de uma série baseando-se apenas nos ruídos brancos até o tempo t . A equação Θ_q é denominada como polinômio de médias móveis de ordem q . Como nesses modelos a variável Z_t é uma combinação linear do ruído ε_t , e supõe-se que esse é iid, assume-se que modelos MA são estacionários por definição (Hipel e McLeod, 1994).

$$\tilde{Z}_t = \Theta_q(B) * \varepsilon_t \quad [\text{Eq. 3.4}]$$

$$\Theta_q(B) = 1 + \theta_1 * B + \theta_2 * B^2 + \dots + \theta_q * B^q \quad [\text{Eq. 3.5}]$$

Esse modelo possui $q + 2$ parâmetros, eles sendo $\theta_1, \theta_2, \dots, \theta_q, \sigma_\varepsilon^2, \mu$. É possível descrever qualquer modelo AR(p) estacionário como um MA(∞). Também sendo possível descrever um MA(q) em um AR(∞), tendo algumas ressalvas em consideração, resultando em uma modelo MA inversível (Hyndman e Athanasopoulos, 2021).

Os modelos MA(q) são inversíveis se, e somente se, o módulo das raízes do polinômio de médias móveis de ordem q , Θ_q , for maior do que 1. Deve-se verificar a condição de inversibilidade para utilização desses modelos de modo que esse faça sentido prático de que as observações recentes tenham uma influência maior no erro atual do que observações infinitamente antigas. O pacote *fable* comentado na seção anterior também pode ser utilizado aqui para tratar dessas restrições de inversibilidade dos q parâmetros de um modelo de médias móveis MA(q) (Hyndman e Athanasopoulos, 2021).

Uma maneira de determinar o valor de q é pelos gráficos ACF e PACF quando se tem um modelo MA(q) inversível, pois é possível descrever esse como um AR puro, trazendo então significância para esses gráficos. O gráfico ACF decai progressivamente com corte a partir de q e o FACP decai para zero sem cortes. Importante notar que qualquer MA(q)

inversível pode ser escrito como $AR(\infty)$, permitindo a construção desses gráficos (Hipel e McLeod, 1994).

3.1.1.3 Modelos ARMA

É possível juntar os modelos $AR(p)$ e $MA(q)$, isso resulta nos modelos $ARMA(p, q)$ – Modelos Autoregressivos de Médias Móveis (Box e Jenkins, 1976). Esse modelo, equação 3.6, é uma junção dos dois modelos vistos anteriormente e, conseqüentemente, descreve uma variável aleatória Z_t a partir dos p valores anteriores, pelo polinômio autoregressivo de ordem p , e pelos q últimos valores do ruído branco, obtidos pelo polinômio de médias móveis de ordem q . De maneira similar aos outros modelos, esse terá $p + q + 2$ parâmetros para serem estimados.

$$\Phi_p(B) * \tilde{Z}_t = \Theta_q(B) * \varepsilon_t \quad [\text{Eq. 3.6}]$$

O processo é estacionário se o módulo das raízes do polinômio autorregressivo for maior do que 1 e é inversível se o módulo das raízes do polinômio de médias móveis for maior do que 1. Caso o modelo seja ambos, estacionário e inversível, os gráficos ACF e PACF decaem para zero de forma amortizada ou oscilando.

O mesmo é válido para os próximos dois modelos comentados (ARIMA e SARIMA). Tais gráficos não dão tanta informação a respeito de qual seriam os valores de p e q caso ambos sejam positivos. Uma alternativa para isso é utilizar um modelo automático que rode diferentes valores de p , q e d e retorne o modelo que tenha o menor valor de AIC (Critério de Akaike) ou AICc (Critério de Akaike corrigido) como proposto por Hyndman e Athanasopoulos (2021), comentado mais a frente nesse texto em uma seção posterior (3.1.5 Seleção do Modelo).

Importante notar que um modelo ARMA costuma necessitar de menos parâmetros do que um modelo AR ou MA, sendo então mais parcimonioso, computacionalmente mais eficiente e, portanto, preferível. Um modelo $ARMA(p, 0)$ equivale a um modelo $AR(p)$ e um modelo $ARMA(0, q)$ equivale a um modelo $MA(q)$. Um cuidado deve ser tomado em modelos do tipo ARMA para que não haja uma redundância na parametrização, isso

significa que as vezes é possível simplificar o modelo ARMA algebricamente para que esse necessite de menos parâmetros.

3.1.1.4 Modelos ARIMA

Esses modelos vistos até aqui foram utilizados apenas para séries estacionárias. Para séries não-estacionárias, utiliza-se os modelos ARIMA(p, d, q), que são modelos ARMA integrados (Box e Jenkins, 1976). Dado um processo não estacionário $\{Z_t\}$, o modelo ARIMA, equação 3.7, consiste em tirar diferenças da série (d vezes) de modo que essa se torne estacionária e, em seguida, se torna equivalente a um ARMA. Isso é feito matematicamente pelo operador de diferença, ∇ , definido para o caso de d igual a 1 pela equação 3.8.

$$\Phi_p(B) * \nabla^d \tilde{Z}_t = \Theta_q(B) * \varepsilon_t \quad [\text{Eq. 3.7}]$$

$$\nabla^1 \tilde{Z}_t = \tilde{Z}_t - \tilde{Z}_{t-1} \quad [\text{Eq. 3.8}]$$

O valor de d pode ser definido fazendo um teste de estacionaridade na série, como o teste KPSS (Kwiatkowski et al., 1992) comentado na seção Assim, esse modelo introduz um viés (controlado por λ) em uma tentativa de melhorar a variância geral da função f proposta, evitando um possível sobreajuste ou *overfitting*. Para definir o valor de λ , usualmente é utilizada uma validação cruzada para avaliar o seu valor ótimo a ser usado para uma situação específica. Ao utilizar $\lambda = 0$, o modelo *ridge* se torna uma regressão linear, com os parâmetros definidos pelo método dos mínimos quadrados. Por outro lado, quando $\lambda \rightarrow \infty$, os parâmetros β_j tendem a zero, conseguindo então encolher esses parâmetros de modo a se tornarem virtualmente nulos (Berk, 2020; James et al., 2013).

3.1.4 Ruídos, Resíduos e Erros. Caso a série falhe no teste, aplica-se um operador de diferença na série e em seguida é avaliado se a nova série passa a ser estacionária. Pode-se continuar fazendo isso até que a estacionariedade seja atingida ou caso um valor limite para o operador de diferença seja alcançado (Hyndman e Athanasopoulos, 2021). Existem diversos testes para avaliar a estacionariedade, com o KPSS sendo apenas um exemplo.

3.1.1.5 Modelos SARIMA

Os equacionamentos mostrados previamente (AR, MA, ARMA e ARIMA) não possuem nenhuma informação sazonal da série histórica e isso é especialmente importante em análises hidroclimáticas, nas quais a sazonalidade possui um papel extremamente importante. Para essa informação estar presente no modelo, existem os modelos SARIMA(p, d, q)x(P, D, Q)[s], ou ARIMA sazonal, descritos na equação 3.9 (Box e Jenkins, 1976).

$$\Phi_P(B^s) * \Phi_p(B) * \nabla_s^D \nabla^d \tilde{Z}_t = \Theta_Q(B^s) * \Theta_q(B) * \varepsilon_t \quad [\text{Eq. 3.9}]$$

Essa equação é similar a equação 3.8 dos modelos ARIMA, porém todos os polinômios e operadores possuem também uma versão sazonal de ordem s . Para séries de dados mensais e contendo sazonalidade anual, $s = 12$, séries mensais com sazonalidade trimestral, $s = 4$ e assim por diante. Dessa forma, o Φ_P (por isso o “P” maiúsculo) é um polinômio autorregressivo de ordem P aplicado aos operadores de retardo B^S . O mesmo serve para o polinômio de médias móveis sazonais, Θ_Q , e para o operador de diferenças sazonais, ∇_s^D .

Os valores de D podem ser encontrados de maneira análoga para como encontrar o valor de d para modelos ARIMA e os valores de P e Q também. Assim, pode-se usar gráficos ACF e PACF para determinar seus valores, porém sendo útil apenas quando P e Q não sejam ambos positivos e maiores do que zero (Hyndman e Athanasopoulos, 2021). Assim, pode ser preferível a avaliação do modelo com diferentes valores para p, q, P e Q , sendo selecionado o melhor por alguma métrica, como o AIC.

3.1.1.6 Estimação dos parâmetros

Os parâmetros dos modelos autorregressivos, AR(p), podem ser estimados por diferentes formas. Uma forma conhecida na literatura estatística e utilizada em modelos autorregressivos no contexto de vazões hidrológicas (Oliveira, 2020) é pelo método de mínimos quadrados ordinários. Esse método (equação 3.10) busca a reta que melhor se ajusta aos dados, de forma a minimizar a soma dos quadrados dos erros (diferença entre

os dados observados, y_i , e a reta proposta pela função $f(x_i)$ – essa reta não sendo obrigatoriamente função de uma única variável explanatória).

$$\min \left\{ \sum_{i=1}^N [y_i - f(x_i)]^2 \right\}; \quad f(x_i) = \beta_0 + \sum_{j=1}^K \beta_j X_j \quad [\text{Eq. 3.10}]$$

Outra maneira de estimar tais parâmetros é resolvendo as equações de Yule-Walker (equação 3.11), que se resume em resolver um sistema de equações lineares criadas a partir das definições e propriedades dos coeficientes mencionados nas seções anteriores. Essas equações permitem o cálculo iterativo da função de autocorrelação desses modelos (Oliveira, 2020; Hipel e McLeod, 1994).

$$\begin{bmatrix} 1 & \rho^{m-1}(1) & \rho^{m-1}(2) & \dots & \rho^{m-1}(\rho_m - 1) \\ \rho^{m-1}(1) & 1 & \rho^{m-2}(1) & \dots & \rho^{m-2}(\rho_m - 2) \\ \rho^{m-1}(2) & \rho^{m-2}(1) & 1 & \dots & \rho^{m-3}(\rho_m - 3) \\ \dots & \dots & \dots & \dots & \dots \\ \rho^{m-1}(k-1) & \rho^{m-2}(k-2) & \rho^{m-3}(k-3) & \dots & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1}^m \\ \phi_{k2}^m \\ \phi_{k3}^m \\ \dots \\ \phi_{kk}^m \end{bmatrix} = \begin{bmatrix} \rho^m(1) \\ \rho^m(2) \\ \rho^m(3) \\ \rho^m(4) \\ \rho^m(5) \end{bmatrix} \quad [\text{Eq. 3.11}]$$

Além desse, existem diferentes outras maneiras de estimar os parâmetros dos modelos mais genéricos do tipo $\text{ARMA}(p, q)$ como, por exemplo, com o método da máxima verossimilhança ou utilizando outros algoritmos específicos (Hipel e McLeod, 1994).

3.1.2 Modelos PAR, PARMA e PARX

3.1.2.1 Modelos PAR

Outra família de modelos estocásticos é a dos modelos periódicos. Ao invés de utilizar um modelo sazonal do tipo SARIMA para compor a sazonalidade do processo, os modelos PAR (Periódicos Autoregressivos) incorporaram ela de uma maneira distinta. A periodicidade pode estar em qualquer parte do modelo, seja na média, variância e/ou nos coeficientes autorregressivos (Salas et al., 1980).

Os coeficientes desses modelos periódicos podem ser estimados da mesma forma que os modelos autorregressivos comentados na seção anterior. Assim suas estimações podem ser feitas pelo método dos mínimos quadrados (equação. 3.10), pelas equações de Yule-Walker (equação. 3.11), pelo método da máxima verossimilhança ou outros.

Para isso, ao invés de avaliar um processo $\{Z_t\}$, é avaliado um processo $\{Z_{v,\tau}\}$. Nele, o índice v define o ano da variável em questão e tem-se que $\tau = 1, \dots, \omega$ com ω sendo o número de períodos existentes em um ano qualquer. Portanto τ pode representar diferentes unidades temporais como semana, mês ou estação. Em suma, modelos PAR criam um modelo AR para cada período τ da série com um análogo sendo feito entre modelos PARMA e ARMA (Hipel e McLeod, 1994; Maidment, 1993; Salas et al., 1980).

Os modelos $PAR(p)$ podem ser escritos de diversas maneiras, Hipel e McLeod (1994) o descreve similarmente como na equação 3.11, dado que $\tilde{Z}_{v,\tau} = Z_{v,\tau} - \mu_\tau$ (variação de Z ao redor da média no período τ). No Brasil o PREVIVAZ, porém, utiliza, sem perda das propriedades ou generalizações, que $\tilde{Z}_{v,\tau} = \frac{Z_{v,\tau} - \mu_\tau}{\sigma_\tau}$ (CEPEL, 2015). Para deixar de forma similar aos modelos da família SARIMA vistos anteriormente, pode-se escrever também os modelos $PAR(p)$ como pelas equações 3.12 a 3.14.

$$\tilde{Z}_{v,\tau} = \sum_{i=1}^p \phi_{i,\tau} * \tilde{Z}_{v,\tau-i} + \varepsilon_{v,\tau} \quad [\text{Eq. 3.12}]$$

$$\Phi_{p,\tau}(B) * \tilde{Z}_{v,\tau} = \varepsilon_{v,\tau} \quad [\text{Eq. 3.13}]$$

$$\Phi_{p,\tau}(B) = 1 - \phi_{1,\tau} * B - \phi_{2,\tau} * B^2 - \dots - \phi_{p,\tau} * B^p \quad [\text{Eq. 3.14}]$$

$$B^p \tilde{Z}_{v,\tau} = \tilde{Z}_{v,\tau-p} \quad [\text{Eq. 3.15}]$$

Diferente dos modelos anteriores, nota-se que como no PAR existe um τ para a periodicidade, existirá um Z dependente de dois índices e, portanto, haverá também uma possível média (μ) e desvio padrão (σ) para cada valor de τ . Assim como nos modelos anteriores, $\varepsilon_{v,\tau}$ é uma variável iid normal com média zero e variância constante. Nota-se que quando $\tau - i \leq 0$ então o processo $Z_{v,\tau-i}$ se torna $Z_{v-1, \omega+\tau-i}$.

3.1.2.2 Modelos PARMA

Assim como ARMA é uma extensão do AR, o PARMA é uma extensão do PAR que inclui também a componente de média móvel, dessa vez periódica (Maidment, 1993). Esse modelo pode ser escrito então como na equação abaixo. De forma semelhante ao visto anteriormente, aparece a componente de médias móveis com seus coeficientes, θ , agora dependentes do ano e da sazonalidade τ .

$$Z_{v,\tau} = \mu_{\tau} + \sum_{i=1}^p \phi_{i,\tau}(Z_{v,\tau-i} - \mu_{\tau-i}) + \varepsilon_{v,\tau} - \sum_{i=1}^q \theta_{i,\tau} * \varepsilon_{v,\tau-i} \quad [\text{Eq. 3.16}]$$

3.1.2.3 Modelos PARX

O modelo PARX consiste em utilizar uma variável exógena (X) e adiciona-la ao modelo PAR já visto anteriormente. Diferentes variáveis exógenas podem ser utilizadas, essas podendo trazer informações externas ao sistema. Ao tratar de uma série temporal de vazões, por exemplo, a variável exógena pode ser a temperatura da superfície de determinada área do oceano, a velocidade de vento em uma altitude específica ou a precipitação na região – quando tratamos de um modelo estocástico, esse não leva em consideração o ciclo hidrológico, portanto dados de precipitação não são incluídos no modelo original para cálculo da vazão.

Lima e Lall (2010a) avaliaram a inclusão de indicadores climáticos, relacionados a temperatura média da superfície do mar em áreas específicas e sua relação com as vazões mensais de hidrelétricas pertencentes ao SIN. O modelo PARX mostrou-se superior ao PAR para 1 e 2 meses a frente, porém se mostrando pior para tempos maiores. O modelo ótimo da análise foi uma regressão *ridge* comentada na seção seguinte.

O uso de modelos PARX com informações climáticas também se mostrou superior ao PAR no estudo de Oliveira e Lima (2016) para previsão das vazões mensais em algumas hidrelétricas brasileiras pertencentes ao SIN. O estudo ainda conclui que a utilização de uma ponderação bayesiana de modelos (BMA) para acoplar a informação da previsão semanal na previsão mensal melhorou ainda mais os modelos PARX.

Seguindo no âmbito de previsões de vazões mensais do SIN, Silveira et al. (2017), também utilizaram um modelo PARX com informações climáticas (27 diferentes). O modelo PARX mostrou-se melhor que o PAR apenas em alguns casos e para alguns meses do ano. Nesse estudo não foi feita a agregação em reservatórios equivalentes de energia, utilizando 88 estações base da ONS e calculando quais índices usar no PARX para cada uma delas.

3.1.3 Regressão *ridge*

Também conhecida como regularização L2, a regressão *ridge* tem como objetivo geral ser uma alternativa mais adequada do que uma regressão linear simples. Isso é feito forçando um aumento do viés do modelo na busca de obter uma redução na variância, conhecido como “*bias-variance tradeoff*”. Assim, a regressão *ridge* é uma forma de selecionar quais variáveis explanatórias serão incluídas em um modelo multivariado e a importância de cada uma delas (Berk, 2020; James et al., 2013).

Dado diversos pontos em uma região K–dimensional, a regressão *ridge* retorna uma reta do tipo $Y = \beta_0 + \beta_1 * X_1 + \dots + \beta_K * X_K$, mas ao invés de obter os parâmetros beta (β_j) por meio dos mínimos quadrados (equação 3.10), este modelo obtém uma estimativa dos parâmetros por uma modificação desse método ao adicionar uma componente de “penalização” dos parâmetros dada pela constante λ , definida na equação 3.17 (Berk, 2020; James et al., 2013).

$$\hat{\beta}_t^{RIDGE} = \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^N [(y_i - f(x_i))^2] + \lambda \sum_{j=1}^K \beta_j^2 \right\} \quad [\text{Eq. 3.17}]$$

Assim, esse modelo introduz um viés (controlado por λ) em uma tentativa de melhorar a variância geral da função f proposta, evitando um possível sobreajuste ou *overfitting*. Para definir o valor de λ , usualmente é utilizada uma validação cruzada para avaliar o seu valor ótimo a ser usado para uma situação específica. Ao utilizar $\lambda = 0$, o modelo *ridge* se torna uma regressão linear, com os parâmetros definidos pelo método dos mínimos quadrados. Por outro lado, quando $\lambda \rightarrow \infty$, os parâmetros β_j tendem a zero, conseguindo então

encolher esses parâmetros de modo a se tornarem virtualmente nulos (Berk, 2020; James et al., 2013).

3.1.4 Ruídos, Resíduos e Erros

Todos os modelos acima contêm uma componente de ruído, também chamado de ruído branco, perturbações ou choques aleatórios, que é uma sequência de termos estocásticos com distribuição probabilística conhecida – usualmente sendo utilizada a distribuição normal. Ruídos e resíduos não são a mesma coisa, o primeiro faz parte dos modelos estocásticos vistos na seção anterior, usualmente representado por ε_t , ou por $\varepsilon_{v,t}$ no caso dos modelos periódicos. Ao ajustar um modelo em uma série histórica para avaliar o ajuste desse, a diferença entre eles é chamada de resíduos (Hipel e McLeod, 1994).

Existem diferentes nomenclaturas e significados para erros e resíduos. Pode-se chamar de erro a diferença entre o valor real e o valor observado, existindo então um erro humano associado a, quando falamos de vazões, medida de cota em um rio ou um erro instrumental em estações telemétricas. De maneira geral, esses erros, também conhecidos como “erro amostral”, podem trazer uma incerteza de difícil quantificação e que são inerentes ao processo, não sendo possível melhorar eles apenas com simulações.

Já resíduos, são comumente descritos pela diferença entre o valor observado e o valor simulado. Uma maneira de rodar simulações e previsões é criando um modelo sem a componente de ruído, e atribuir o resíduo ao ruído, assumindo então que o resíduo é causado inteiramente pelo ruído do modelo. Em seguida pode-se testar os resíduos, ou ruídos, de um modelo que, nesse caso, seriam a mesma coisa. Também é comum chamarem esses resíduos de erros (erros do modelo em si), inclusive o nome de diversas métricas para avaliar esses resíduos são chamadas de erros (erro quadrático médio, erro médio absoluto e outros).

É possível assumir outras distribuições não-normais para o ruído como, por exemplo, uma distribuição gamma de três parâmetros, como descrito na equação 3.18 (Maidment, 1993), uma distribuição log-normal ou diversas outras. Os três parâmetros presentes nessa equação (λ , ϕ e η) são, respectivamente, os parâmetros de locação, escala e forma. Isso pode ser usado, por exemplo para modelos GAR (Gamma Autoregressivo) ou GAR

periódicos (Maidment, 1993). Neste trabalho, porém, assumimos apenas que o ruído dos modelos possui uma distribuição normal.

$$\varepsilon = \lambda * (1 - \phi) + \eta \quad [\text{Eq. 3.18}]$$

Ao assumir que o ruído, ou como comentado, resíduo, do modelo é iid e segue distribuição normal, este deve ser avaliado para que sejam verificadas tais condições. É importante então testar a estacionariedade, independência e normalidade dos resíduos. Pode ser argumentado que a independência é o critério mais importante a ser verificado uma vez que existem transformações para melhorar a normalidade e estacionariedade da série, como de Box-Cox (Hipel e McLeod, 1994).

Uma possibilidade para verificar a independência da série é utilizando uma modificação do teste de Box-Pierce, feito por Ljung-Box (Ljung e Box, 1978). Apesar do método de Ljung-Box ser amplamente utilizado, existem outros testes mais modernos na literatura. Uyanto (2020) compara a qualidade de 5 diferentes testes, com Ljung-Box ficando em segundo ou terceiro colocado a depender da avaliação feita. Assim, mesmo não sendo o método mais moderno, ele possui uma validação teórica e prática, mesmo quando comparado com testes mais recentes na literatura.

A estacionariedade dos resíduos pode ser testada pelo teste KPSS (Kwiatkowski et al., 1992), por exemplo. Esse toma como hipótese nula a ausência de uma raiz unitária na série sendo testada, ou seja, a estacionariedade da série. Dessa forma, a série é tida como estacionária caso a hipótese nula não seja rejeitada. É uma alternativa a outros testes existentes na literatura que tomam a hipótese nula como a presença de uma raiz unitária.

A normalidade dos resíduos pode ser testada pelo teste de Shapiro-Wilk (Shapiro e Wilk, 1969). Ele toma como hipótese nula que uma amostra, retirada de uma população normal, possui distribuição normal. Existem outros testes como o de Kolmogorov-Smirnov e Lilliefors ou até mesmo métodos gráficos (QQplot, histogramas) e numéricos para verificar se é válida a suposição de normalidade.

Razali e Wah (2011) avaliaram 4 testes para normalidade, eles sendo de Shapiro-Wilk (SW), Kolmogorov-Smirnov (KS), Lilliefors (LF) e Anderson-Darling (AD). Foi

mostrado que o de SW é o melhor dos quatro para diferentes distribuições e tamanhos amostrais, porém foi apontado que nenhum dos 4 são ideais para amostras pequenas ($n < 30$). Esse resultado apoia outros na literatura comentados no próprio artigo de Razali (Razali e Wah, 2011).

Outra importância acerca desses resíduos dos modelos são quando se quer fazer uma previsão intervalar. Para previsões pontuais, o valor esperado do ruído é 0. Portanto, caso os resíduos sejam não correlacionados, mas não sejam normalmente distribuídos (não passando no teste de SW por exemplo), é possível fazer a previsão intervalar baseado em intervalos por *bootstrap*, que utiliza erros passados para tentar avaliar o erro futuro por meio de repetição. Esse método, porém, vem com um custo computacional maior (Hyndman e Athanasopoulos, 2021).

Além desses testes estatísticos, é comum plotar os próprios resíduos para uma análise visual, de forma a confirmar os comportamentos esperados dos resíduos, de um ruído branco, como a média igual a zero e a variância constante (homocedástico). Também é comum plotar os gráficos ACF e PACF dos resíduos de modo a examinar se esses estão dentro dos limites aceitáveis, comentados anteriormente. Ademais, é comum avaliar os resíduos também para a seleção do modelo ótimo.

3.1.5 Seleção do Modelo

Existem diversas possibilidades de modelos dentro de uma mesma família, sendo necessário um mecanismo para avaliar qual o mais adequado para a série em questão. Essa definição de mais adequado é um tanto complexa. Box e Jenkins (1976) definem que o melhor modelo possível é aquele mais parcimonioso, não necessariamente sendo o modelo com menor erro. Isso significa escolher aquele que consiga representar adequadamente a série histórica com o menor número de parâmetros possível – quanto maior o número de parâmetros, maior o custo computacional e é concebível que um número maior de parâmetros acabe tendo um *overfitting* (sobreajuste) dos dados, criando piores previsões.

Para essa escolha, um método muito utilizado é o critério de informação de Akaike (AIC), proposto em 1972 com reimpressão em 1992 (Akaike, 1992) mostrado na equação 3.19.

Nela, k é o número de parâmetros do modelo e \hat{L} a máxima verossimilhança dele. Assim, como a escolha ótima possui o menor valor de AIC, o número de parâmetros serve como uma penalização, aumentando o valor do AIC. Desse modo é possível utilizar esse critério apenas para comparar modelos de uma mesma família, por exemplo um AR(5) com um ARIMA(2, 0, 1), pois ambos são da mesma família de modelos (ambos podem ser escritos como um modelo ARIMA ou SARIMA). Mas não é recomendado comparar modelos autorregressivos com outros tipos.

$$AIC = 2 * k - 2 * \ln(\hat{L}) \quad [\text{Eq. 3.19}]$$

Além disso é importante lembrar que, dentro das famílias SARIMA, não é recomendado utilizar o AIC para selecionar o valor de d ou D . Isso ocorre porque ao tirar pelo menos uma diferenciação dos dados de um processo $\{Z_t\}$, são alterados os dados em que a máxima verossimilhança é calculada, tornando então os valores de AIC não comparáveis entre si (Hyndman e Athanasopoulos, 2021).

Apesar do AIC ser um método simples, facilmente interpretável e rápido de ser calculado, ele possui alguns problemas como apontados por Burnham e Anderson (2002). Quando se tem uma pequena série amostral (n) em comparação com o número de parâmetros (k) é recomendado utilizar um AIC corrigido (AIC_c), Burnham e Anderson (2002) defendem o uso do AIC_c quando $\frac{n}{k} < 40$. Caso o contrário, o AIC_c tende ao mesmo resultado do AIC, mostrando-se desnecessário. É importante notar que não se deve misturar ambos os critérios, apenas selecionar aquele que se adequa melhor ao problema e utilizar ele para avaliar todos os modelos.

O AIC não é capaz de discernir se o modelo em questão é de fato bom ou até mesmo aceitável, esse critério é utilizado apenas para comparar modelos de uma mesma família ou mesmo grupo, definindo qual deles é o mais parcimonioso em comparação aos outros. Para definir qual modelo é o ótimo, deve-se utilizar outros métodos para avaliação (Burnham e Anderson, 2002). Comumente é feita uma análise dos resíduos dos modelos quando comparados aos dados observados, existindo diversos equacionamentos diferentes que os utilizam. Esses resíduos também são comumente chamados de erro.

3.1.6 Avaliação do Modelo

A seleção de modelos entre uma mesma família é comumente feita pelo AIC como visto anteriormente, mas para escolher entre modelos fundamentalmente diferentes, usualmente é feita uma análise de seus resíduos. Selecionar uma métrica para avaliar o desempenho de um modelo hidrológico e fazer uma comparação entre diferentes séries não é algo trivial. Existem inúmeros indicadores de desempenho possíveis e que são utilizados na literatura, cada um com propostas e significados diferentes. Hall (2001), por exemplo, apresenta 10 formas comuns na literatura de medir a qualidade de um modelo de vazão diária com muitas outras existindo e sendo amplamente utilizadas.

O PREVIVAZ (CEPEL, 2015) utiliza o RMSE (*Root Mean Squared Error*, ou Raiz do Erro Quadrático Médio) da equação 3.20 a seguir para escolher o melhor modelo, mas existem diversos equacionamentos e propostas diferentes para fazer essa seleção e para avaliar, quantitativamente, a qualidade de um modelo.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Q_{s,t} - Q_{o,t})^2}{n}} \quad [\text{Eq. 3.20}]$$

Onde,

$Q_{s,t}$ = Vazão simulada no tempo t ;

$Q_{o,t}$ = Vazão observada no tempo t ;

n = quantidade de dados observados.

Uma vantagem do RMSE é que ele mantém a mesma unidade do que se está avaliando. Por exemplo, ao avaliar o RMSE de vazões mensais em m^3/s , a métrica retorna valores nessa mesma unidade, dando uma noção de escala para o erro das simulações. Com isso ganha-se uma facilidade na interpretação dele, por exemplo, um modelo pode estar errando $5 \text{ m}^3/\text{s}$ nas simulações. Caso estejamos falando de um rio com uma vazão alta ou baixa, esse mesmo $5 \text{ m}^3/\text{s}$ pode significar qualidades preditivas diferentes.

Isso é um ponto contra a utilização do RMSE. Além disso, o presente estudo trabalha com mais de 100 séries históricas, dando diferentes significados para um erro de $5 \text{ m}^3/\text{s}$ em diferentes hidroelétricas. Outro fator não recomendado para o RMSE nesse estudo é que

foram utilizadas também unidades diferentes (utilizando m^3/s para avaliar UHEs individuais, mas MWmed quando agregando as usinas em REEs ou Subsistemas).

Por tais motivos, alguns estudos preferem a utilização do RRMSE (RMSE relativo), dando uma informação percentual ao invés de absoluto. Outras métricas similares recomendadas são, por exemplo o PBIAS que avalia o viés, dando informação se o modelo erra 5 m^3/s tanto para mais quanto para menos (dando informação se o modelo está a subdimensionar ou superdimensionar as vazões) ou o MAE (erro médio absoluto) que, ao não avaliar os erros ao quadrado, se dá uma importância menor para erros cometidos em vazões mais altas (épocas de cheias).

Outra métrica interessante que existe é a de Distância Multicritério (DM), desenvolvida pelo ONS (2010) e utilizada por Oliveira e Lima (2016) e por Silveira et al. (2017) para avaliar previsões, demonstrada na equação 3.21. A ideia por trás desse critério é utilizar dois indicadores comuns, um de curto prazo e outro de longo prazo. O de curto é dado pelo coeficiente de Nash-Sutcliffe (NSE), comentado na sequência, enquanto o outro é dado pelo Erro Médio Percentual Absoluto, ou MAPE (*Mean Absolute Percentage Error*) – equação 3.22 (os significados das variáveis seguem o mesmo da equação 3.20 anterior).

$$DM = \sqrt{(1 - NSE)^2 + MAPE^2} \quad [\text{Eq. 3.21}]$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Q_{s,t} - Q_{o,t}}{Q_{o,t}} \right| \quad [\text{Eq. 3.22}]$$

Esse indicador está exemplificado graficamente na Figura 3.4. Em um plano cartesiano em R^2 , plota-se em um dos eixos o valor do MAPE do modelo em questão, e no outro eixo o valor de $(1 - NSE)$. A distância multicritério (DM) é calculada pela distância euclidiana do par ordenado dado pelo MAPE e $(1 - NSE)$ até o ponto ótimo deste plano cartesiano. Esse ponto ótimo é a origem do plano, com par ordenado igual a $(0, 0)$, quando $NSE = 1$ e $MAPE = 0$ (ONS, 2010). Essa é uma abordagem interessante por combinar diferentes métricas e ideias em um indicador único, abrindo outras opções também como colocar pesos para cada eixo de modo a modificar a importância de cada métrica.

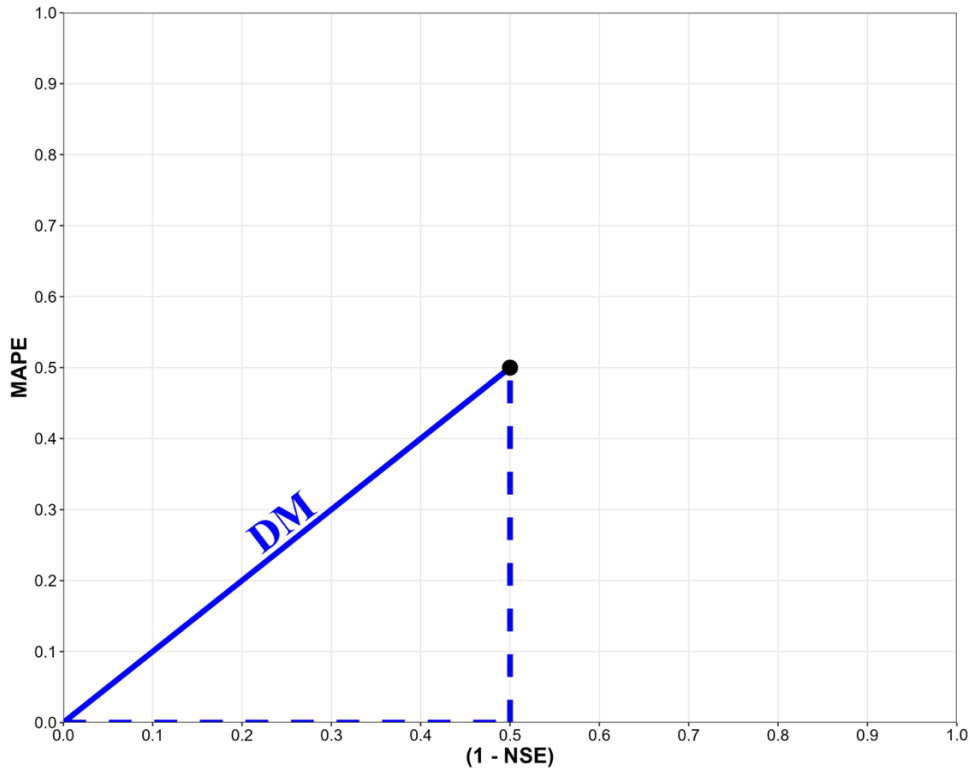


Figura 3.4 Demonstração gráfica da distância multicritério (DM)

A outra componente da distância multicritério, equação 3.21, é um índice muito utilizado em estudos hidrológicos denominado como o coeficiente de eficiência de Nash Sutcliffe, referido nesse texto como NSE, proposto na década de 70 (Nash e Sutcliffe, 1970). Essa métrica “é, de longe, o índice mais utilizado em aplicações hidrológicas” (Todini e Biondi, 2017, *apud* Lamontagne et al., 2020, tradução nossa). De fato, isso pode ser validado de certa forma com a quantidade de citações do artigo original no *google scholar* (25.900 até o dia 17/07/2023).

O NSE é regido pela equação 3.23 abaixo e pode ser interpretado como uma medida do MSE (*Mean Squared Error* ou Erro Quadrático Médio). Na equação, $Q_{s,i}$ é a vazão simulada no tempo i , $Q_{o,i}$ é a vazão observada nesse mesmo tempo e Q_o^* é a média aritmética de todas as vazões observadas. \overline{MSE} e s_o são estimadores do MSE e do desvio padrão dos valores observados, respectivamente.

$$NSE = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (Q_{s,i} - Q_{o,i})^2}{\frac{1}{n-1} \sum_{i=1}^n (Q_{o,i} - Q_o^*)^2} = 1 - \frac{\overline{MSE}}{s_o} \quad [\text{Eq. 3.23}]$$

Esse indicador pode variar entre $-\infty$ e 1 (incluindo 1), com 1 sendo o valor ótimo. Qualquer valor menor do que 0 indica que utilizar a média das vazões como previsão seria um modelo mais adequado (denominado como modelo “nulo”) do que o proposto. Esse modelo nulo é claramente insatisfatório quando se trata de séries com sazonalidades, portanto valores negativos são evidentemente insatisfatórios.

Escrever o NSE como função dos estimadores \overline{MSE} e s_o foi algo feito por Lamontagne et al. (2020), equação um pouco diferente da original, quando antes utilizavam (na literatura) apenas o MSE e o σ_o e, portanto, não havia esse $\frac{1}{n}$ ou $\frac{1}{n-1}$ na fração dessa métrica. Lamontagne et al. (2020) comentam sobre o fato desse NSE ser apenas um estimador para o coeficiente de eficiência, pois só temos acesso a uma realização do processo estocástico que é a vazão. Assim, utilizamos da inferência estatística para, a partir da amostra de dados observados, podermos fazer generalizações sobre a população e, portanto, do coeficiente de eficiência de fato (E).

Apesar de seu uso extenso na literatura, essa métrica possui alguns problemas – assim como qualquer outra, não existindo até o momento uma métrica que seja universalmente utilizada. Um problema existente é a interpretação do seu valor. Definir o que seria um valor aceitável ou bom do NSE é uma tarefa complexa e diversos pesquisadores já tentaram achar uma solução.

Beran (1999) conclui que só se deveria estar satisfeito com valores acima de 0.95. Enquanto Shalmsedin, 1997, *apud* Hall, 2001, sugere que o NSE deve estar acima de 0.8 para ser satisfatório e acima de 0.90 para ser de fato bom. Nota-se que não apenas valores negativos são insatisfatórios. Esses estudos utilizaram dados diários de vazões para essas análises e para definir esses limiares.

Já Moriasi et al. (2007) separaram o NSE em quatro classes: Insatisfatório, Satisfatório, Bom e Muito Bom – como na Tabela 3.1 abaixo. Foram utilizados por ele principalmente vazões diárias e mensais, mas também dispuseram de vazões semanais e anuais, sendo então uma revisão extensa do método. Nesse estudo, apresentaram que o NSE usando vazões diárias tende a ser maior do que utilizando valores mensais. A Tabela 3.1 é para os dados mensais, portanto caso se queira utilizar as classes propostas por Moriasi et al.

(2007) para dados diários ou semanais é necessário um ajuste das faixas. Esse ajuste também é recomendado para quando os dados não são de boa qualidade. Em ambos os casos o ajuste deve ser no sentido de uma maior restrição para os valores de NSE.

Tabela 3.1 – Classes do NSE segundo Moriasi et al. (2007) para dados mensais

Performance	NSE
Muito bom	$0.75 < \text{NSE} \leq 1.00$
Bom	$0.65 < \text{NSE} \leq 0.75$
Satisfatório	$0.50 < \text{NSE} \leq 0.65$
Insatisfatório	$\text{NSE} \leq 0.50$

Outra crítica colocada por Beran (1999) é sobre a hipótese nula do NSE (também criticada por Gupta et al., 2009). A premissa dessa métrica é que alguém sem conhecimento acerca de modelagem hidrológica iria utilizar apenas a média das vazões. Porém, Beran (1999) diz que essa seria uma hipótese nula irrealista, que acarretaria um erro do tipo 1 (rejeitar uma hipótese nula verdadeira). Uma pessoa sem grandes conhecimentos hidrológicos e estatísticos é capaz de criar um modelo melhor para avaliação do que a média histórica das vazões, como a média da estação chuvosa / seca, a média mensal das vazões ou outras diferentes maneiras.

Hall (2001) também cita o fato de que mesmo caso seu modelo consiga prever com exatidão os valores observados ($\text{NSE} = 1$) mas os valores simulados estejam defasados no tempo, é possível que o NSE caia para aproximadamente 0.5 (insatisfatório por todos os padrões comentados na literatura acima). O mesmo pode acontecer caso os valores simulados estejam enviesados por uma constante ou sejam um múltiplo constante dos valores observados (erro de volume), sendo possível o NSE ficar negativo quando acontecem em conjunto com a defasagem no tempo. Isso mostra a importância de não apenas rejeitar um modelo caso o NSE tenha valor baixo / negativo, mas interpretar melhor esses valores, uma vez que todos esses poderiam ser corrigidos facilmente, como tirando a diferenciação das vazões para ajuste temporal dos dados (Hall, 2001).

Diversas adaptações do NSE já foram propostas na literatura, analisando as problemáticas comentadas anteriormente. Uma análise interessante do NSE foi feita por Gupta et al.

(2009), em que descrevem o NSE pelas equações 3.24, 3.25 e 3.26 abaixo. Nelas, r é a correlação linear entre as vazões observadas e simuladas, μ_s e μ_o são o primeiro momento estatísticos (média) e σ_s e σ_o são o segundo momento estatístico (desvio padrão) das vazões simuladas e observadas, respectivamente.

$$\text{NSE} = 2 \cdot \alpha \cdot r - \alpha^2 - \beta_{NSE}^2 \quad [\text{Eq. 3.24}]$$

$$\alpha = \frac{\sigma_s}{\sigma_o} \quad [\text{Eq. 3.25}]$$

$$\beta_{NSE} = \frac{(\mu_s - \mu_o)}{\sigma_o} \quad [\text{Eq. 3.26}]$$

Essa forma de escrever o NSE é interessante porque se tem uma outra visão dos mecanismos internos dele. Ao invés de apenas associá-lo ao MSE, essa relação é feita com três componentes: a correlação (r), com valor ideal de 1, o viés normalizado pelo desvio padrão dos valores observados (β_{NSE}), com valor ideal de 0, e uma variância relativa (α), com valor ideal de 1.

Um novo problema percebido por Gupta et al. (2009) ao fazer essa distinção foi que ao maximizar o NSE, não se atinge os três valores ideais de r , α e β_{NSE} . Pode ser demonstrado trivialmente que o NSE é máximo quando $\alpha = r$ e não quando $\alpha = 1$ (valor ideal). Isso resulta em favorecer modelos que subestimam a variabilidade das vazões, ou seja, modelos em que $\sigma_s < \sigma_o$. Além disso, essa métrica favorece também séries com desvios padrões observados (σ_o) mais altos (diminuindo o valor de β_{NSE}).

Assim, Gupta et al. (2009) propõem um novo índice, que atualmente também é utilizado na literatura hidrológica, denominado KGE (Critério de Eficiência de Kling-Gupta) e descrito pelas equações 3.27 e 3.28 baseadas nas mesmas ideias dos três componentes utilizados pelo NSE. Nota-se que o valor de β não é o mesmo para o KGE e o NSE e por isso estão com subscritos diferentes.

$$\text{KGE} = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta_{KGE} - 1)^2} \quad [\text{Eq. 3.27}]$$

$$\beta_{KGE} = \frac{\mu_s}{\mu_o} \quad [\text{Eq. 3.28}]$$

A ideia por trás desse equacionamento é calcular a distância euclidiana em um plano tridimensional, R^3 , de um ponto simulado (com valores de r , α e β_{KGE}) até o ponto ótimo, onde $r = 1$, $\alpha = 1$ e $\beta_{KGE} = 1$ (logo, quando o $KGE = 1$). Portanto, nesse caso, um mesmo peso é dado para cada componente nessa equação. Também propuseram um formato KGE' , em que cada componente da equação é multiplicada por um fator de escala “ s ” para cada eixo/parâmetro, sendo possível dar diferentes pesos para cada componente (Gupta et al., 2009).

É importante notar que o KGE apresenta diversas vantagens em relação ao NSE , e por isso vem sendo utilizado com frequência. Ainda assim, o índice KGE continua com uma tendência de subestimar cheias e superestimar secas, porém de uma maneira menos agravante que o NSE (Gupta et al., 2009). Outro defeito do KGE , apontado por Lamontagne et al. (2020), é em relação a suposição que os dados são bivariados e normalmente distribuídos – o que nem sempre é uma boa hipótese, especialmente para dados de vazões diárias.

Se faz necessário entender que o NSE e o KGE não representam a mesma coisa. Como colocado por Lamontagne et al. (2020), o NSE tem uma ligação direta com o MSE enquanto o KGE é uma métrica criada arbitrariamente com um formato similar ao NSE , contendo a mesma ideia central do índice quando escrito como função de três componentes de correlação, viés e variabilidade. Portanto, os coeficientes de eficiência relacionados a cada um deles são diferentes e devem ser tratados como tal (determinado valor de um não traduz para o outro).

Mais do que isso, em realidade, o NSE é apenas um estimador para o seu respectivo coeficiente de eficiência. O mesmo pode ser dito para o KGE e seu coeficiente de eficiência, lembrando que esses coeficientes são diferentes e, portanto, os estimadores NSE e KGE não estimam a mesma coisa (Lamontagne et al., 2020).

Inclusive, Knoben et al. (2019) demonstram matematicamente que a noção de valores negativos como sendo “ruins” pelo NSE não se traduz para o KGE , com a ideia do modelo nulo em que $NSE = 0$, no caso do KGE ficaria em torno de -0,41. Mesmo assim, os autores (Knoben et al., 2019) reforçam a noção de que ambas as métricas não são equivalentes e reforçam a precaução em comparar tais valores.

Lamontagne et al. (2020) apresentam uma leitura crítica e análise mais profunda sobre o NSE e KGE, apresentando uma possibilidade de índices que possam ser mais representativos. Como ambas as métricas são apenas estimadores de coeficientes de eficiência (diferentes) e tendo em vista que não se tem acesso aos valores populacionais, mas apenas de uma realização de um processo estocástico, é sugerido a utilização de uma métrica desenvolvido por eles (LBE e LBE' no lugar do NSE e KGE, respectivamente). Porém, essas novas possibilidades são ainda recentes, e necessitam de maiores verificações para uso geral, como apontado por eles próprios.

3.2 SISTEMA HIDROELÉTRICO BRASILEIRO

A matriz elétrica brasileira é fortemente dependente das hidrelétricas – representando cerca de 64% da fonte de eletricidade produzida no país em 2020. Outras fontes, como a energia eólica, têm ganhado destaque na última década, aumentando sua produção em mais de 26 vezes nesse tempo e representando cerca de 9% da matriz elétrica brasileira em 2020. Apesar da contribuição das hidrelétricas ter diminuído (era em torno de 90% em 2007), elas continuam como o destaque nacional nesse setor (MME, 2020; IEA, 2020). A Figura 3.5 traz as matrizes do Brasil para o ano de 2020.




Figura 3.5 Matriz Elétrica e Energética do Brasil no ano de 2020

Esse padrão deve continuar nos próximos anos, mesmo com o crescimento da utilização de outras fontes renováveis como solar e eólica, pode-se dizer com certa segurança que as hidroelétricas permanecerão como a mais relevante para a matriz elétrica brasileira. De

Faria e Jaramillo (2017) avaliaram alternativas, especialmente eólicas, para o desenvolvimento das hidrelétricas na região amazônica planejada até 2028, mostrando as complexidades envolvidas na escolha, não mostrando um cenário que consegue ser ótimo em todos os pontos visitados (custos de operação, emissão de GEE e área necessária para implementação dos projetos).

No planejamento para 2025 (realizado em 2021), existe a ambição de aumentar a capacidade instalada no SIN pelas hidrelétricas em quase 600 MW (acréscimo de 0,5%), porém, esse aumento implica em uma diminuição da contribuição percentual das hidrelétricas para a matriz elétrica brasileira como um todo. Isso porque outras fontes renováveis devem crescer mais como, por exemplo, a capacidade eólica em 5.066 MW (acréscimo de 27%) e a solar em 2.354 MW, essa representando um aumento de quase 55% nesse setor (ONS, 2021a).

3.2.1 SIN e o ONS

O Sistema Interligado Nacional (SIN) é um sistema de produção e transmissão de energia elétrica brasileiro predominantemente composto por hidroelétricas, mas contendo também estações térmicas e eólicas (Figura 3.6). As estações não-hidroelétricas do SIN são extremamente importantes para a segurança do sistema e são, frequentemente, despachadas a depender das condições hidrológicas. Dessa maneira, como as vazões naturalmente possuem comportamento sazonal e incerto, é importante essa operação conjunta de usinas termoeletricas de complementação (CEPEL, 2015).

Além disso, como a energia hidroelétrica depende, fortemente, das vazões fluviais e, como essa possui comportamento em parte aleatório, se faz necessário também do uso de reservatórios de acumulação (responsáveis pela regularização das vazões fluviais) na operação das hidroelétricas. Isso tudo é feito, hoje, pelo Operador Nacional do Sistema Elétrico (ONS) com a ajuda de modelos desenvolvidos pelo Centro de Pesquisas de Energia Elétrica, CEPEL (CEPEL, 2015; Zambon, 2015; Costa et al., 2007).

O ONS também cuida, desde 2017, dos sistemas isolados, ou seja, aqueles que não estão conectados no SIN. Atualmente são 212 localidades concentradas, principalmente, no Norte. Apesar de serem importante para levar eletricidade para todos os brasileiros e

apesar da sua contribuição ser, em termos de MW, razoável, proporcionalmente ao resto do país, a carga desse sistema não chega a 1% do restante do Brasil (ONS, 2021b).



Figura 3.6 SIN com usinas hidroelétricas (triângulos) e térmicas, representadas por quadrados (modificado – SINDAT, 2021)

É importante notar que a operação ótima não depende apenas das vazões, mas também da demanda futura de eletricidade, disponibilidade e preço dos combustíveis, restrições dos níveis de armazenamento dos reservatórios, riscos e da relação entre os reservatórios. (Zambon, 2015). Isso traz diversas incertezas na análise e planejamento operacional assim como um aumento da complexidade do sistema.

Incertezas vem do nosso conhecimento limitado acerca de um assunto qualquer e envolvem, naturalmente, uma subjetividade. Uma gestão positiva do sistema elétrico brasileiro depende não apenas da previsão das vazões, mas de muitas outras variáveis complexas que trazem em si uma incerteza. Além das variáveis diretamente relacionadas

às hidrelétricas e ao sistema elétrico brasileiro, existem outras que também impactam o sistema, tais como mudanças climáticas, eventos extremos/raros, a demanda a longo prazo de energia e como as cidades vão crescer no futuro – essas caem no que pode ser chamado de *deep uncertainty* ou incertezas profundas (Marchau et al., 2019).

Incetezas profundas são aquelas em que especialistas não compreendem completamente o contexto externo do sistema ou como o próprio sistema funciona, especialmente em nas suas condições de contorno. Tais incertezas também podem vir de situações imprevisíveis. Para planejamentos de longo prazo, é normal que elas existam, porém deve-se escolher levar elas em consideração ou não, mesmo sabendo que ignorar tais incertezas é ignorar a realidade. Idealmente precisa-se tomar tais incertezas profundas em consideração sistematicamente, existindo diversas técnicas recentes para que isso seja feito (Marchau et al., 2019).

A operação de um sistema hidrotérmico brasileiro pode ser descrita como uma relação futura, essa podendo ser de curto, médio ou longo prazo, a respeito do nível do reservatório e da demanda elétrica populacional. A relação entre os modelos hidrológicos utilizados pelo ONS na operação do SIN estão mostrados pela Figura 3.7. Nota-se que existem três variações do PREVIVAZ (modelo estocástico) para diferentes escalas de tempo, o PREVIVAZH, PREVIVAZ e PREVIVAZM (este último não sendo utilizado oficialmente, apenas para estudos de apoio) para previsões de afluências diárias, semanais e mensais, respectivamente.

O PREVIVAZ é utilizado para a operação de curto prazo pelo DECOMP, mas também é utilizado para auxiliar no PREVIVAZM, PREVIVAZH e GEVAZP – esse último criando cenários sintéticos de Energia Natural Afluente (ENA) e, portanto, ajudando ainda no planejamento a médio prazo pelo programa NEWAVE (Costa et al., 2007). Os manuais de metodologia dos modelos PREVIVAZ, DECOMP e NEWAVE são disponíveis para o público geral livremente (CEPEL, 2015; CEPEL, 2018; CEPEL, 2019), juntamente com outros manuais dos outros programas.

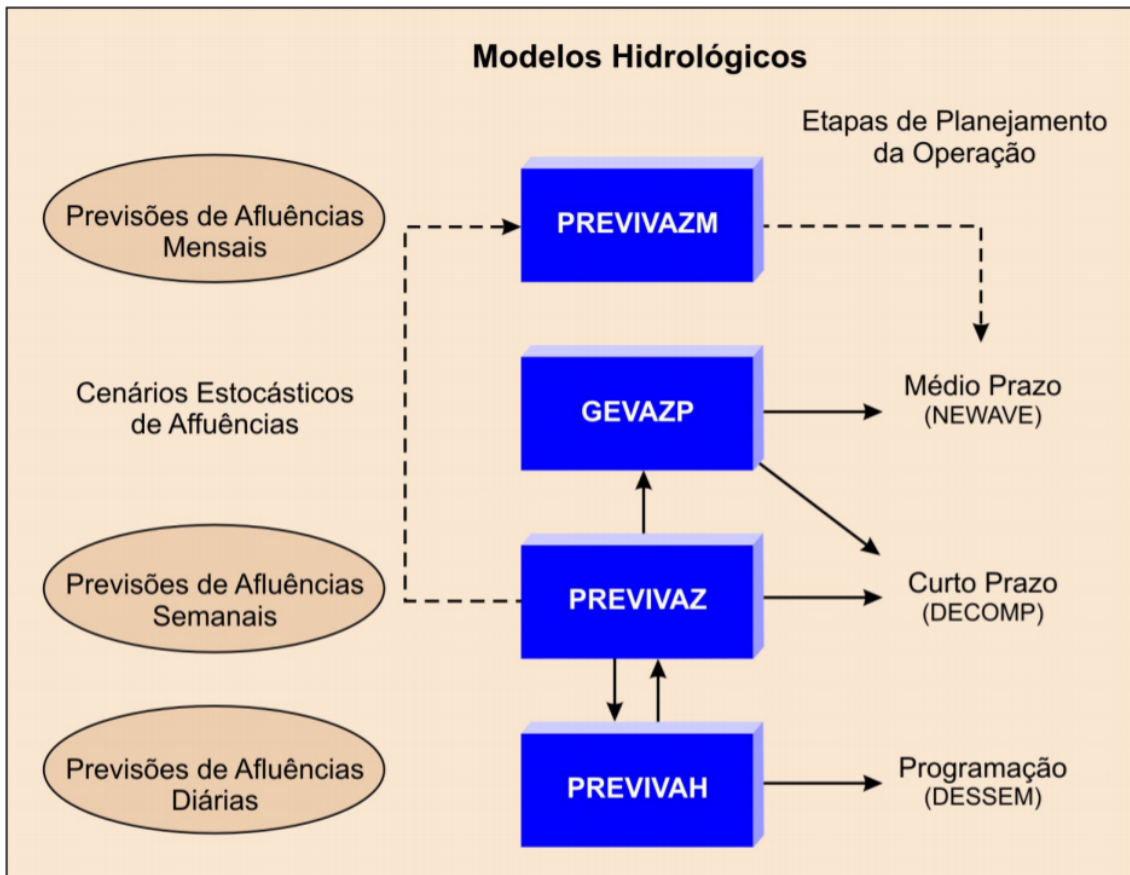


Figura 3.7 Modelos Hidrológicos e para Planejamento da Operação do SIN (Costa et al., 2007)

O tomador de decisão deve, portanto, a partir de previsões e de cenários sintéticos sobre a energia afluente futura, decidir acerca do acionamento ou não das termelétricas pensando tanto no curto prazo quanto a médio prazo. Os modelos dispostos na Figura 3.7 não determinam a operação do sistema, mas auxiliam na tomada de decisão, otimizando então os recursos existentes.

A decisão, de maneira simplificada, é: com base em um certo cenário, deve-se decidir entre utilizar a água retida nos reservatórios ou não para a geração de energia elétrica (consequentemente optando por acionar ou não as termoelétricas para auxiliar na geração de energia elétrica – sistema hidrotérmico). De um ponto de vista de custos, utilizar a água nos reservatórios não possui custo imediato e tem um custo futuro desconhecido, pois as afluências futuras do reservatório são desconhecidas.

Essa decisão está resumida na Figura 3.8. Caso a previsão seja coerente com o que vem de fato a acontecer, não há perdas significativas no sistema (caixas verdes na figura).

Porém caso a previsão não esteja correta, haverá alguma penalidade (caixas vermelhas). Por isso, para que seja tomada uma decisão efetiva baseada em fatos, é importante trazer nos programas utilizados os riscos associados a esses possíveis erros, principalmente pelo fato das aflúências futuras serem desconhecidas ao tomar decisões operacionais – criando um problema estocástico (CEPEL, 2019; CEPEL, 2018).

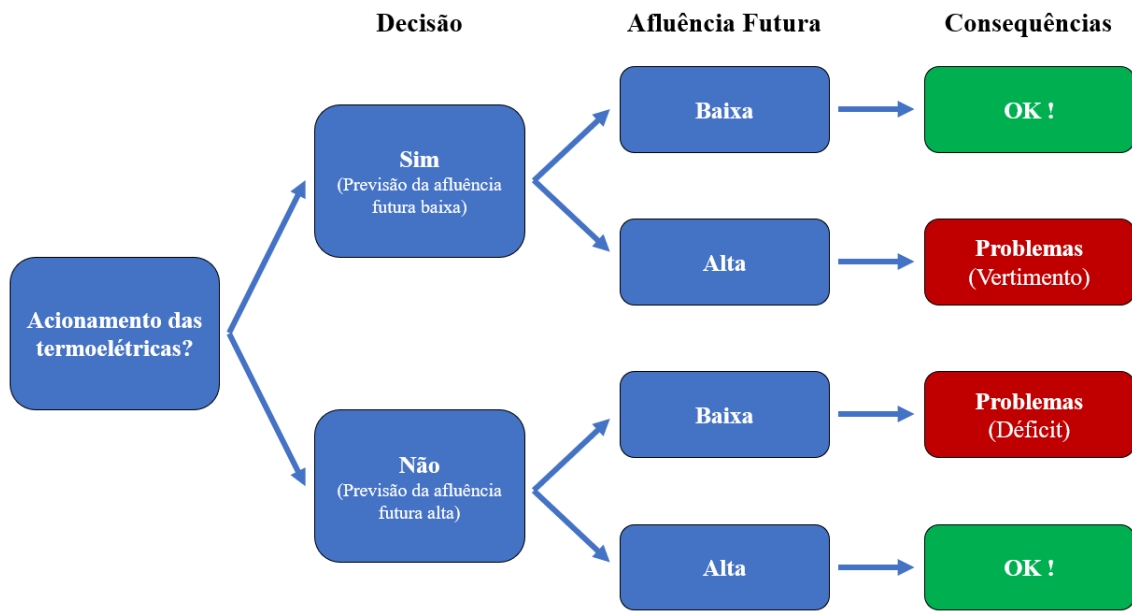


Figura 3.8 Árvore de decisão sobre a operação de um sistema hidrotérmico

Sabe-se que há dois tipos de erros nessas previsões. Um caso sendo quando as previsões indiquem, falsamente, que as aflúências futuras serão baixas, ou seja, optando-se por reter a água no reservatório. Nesse cenário poderia ser recomendando então, erroneamente, o acionamento das termoeletricas. Como as termoeletricas possuem um custo elevado de operação, seu acionamento sem necessidade implica em um prejuízo financeiro. Além disso, caso os reservatórios hidroelétricos estejam com níveis altos, poderá haver um vertimento das águas e, portanto, uma perda econômica (CEPEL, 2019; CEPEL, 2018).

O outro caso é quando as previsões indicam, equivocadamente, que haverá uma aflúência futura alta o suficiente – dando o entendimento de ser compatível para poder gerar energia elétrica que satisfaça a demanda futura da população. Esse cenário implicaria em uma utilização da água do reservatório e um não acionamento das termoeletricas. Porém, caso essa previsão esteja errada e as hidroelétricas não possuam capacidade elétrica o suficiente,

poderia faltar energia em áreas do Brasil ou poderia ser necessário ter que acionar as termoeletricas por um tempo maior ainda (CEPEL, 2019; CEPEL, 2018).

3.2.2 Previsões no SIN

Mostra-se então a importância de se ter a melhor previsão o possível fazendo uma análise também dos riscos envolvidos assim como das incertezas. Assumindo a interpretação de Marchau et al. (2019), que diz existir quatro níveis de incerteza entre a total certeza e total ignorância, os modelos estocásticos representam um nível dois (mais próxima a total certeza) de quatro. Isso significa que os modelos estocásticos utilizam de propriedades de probabilidade e estatística, usando intervalos de confiança para lidar com níveis aceitáveis de risco de forma quantitativa.

A vazão que chega a um reservatório depende da vazão do reservatório a montante desse sistema e possui também uma dependência temporal, sendo parte dessa dependência pela capacidade de geração futura de um reservatório determinada por previsões das vazões futuras. Essas dependências tornam a operação do sistema ainda mais complexo (CEPEL, 2019; Costa et al., 2007).

As previsões dos modelos utilizados determinam quanto da demanda elétrica deve ser atendida pelos reservatórios hidroelétricos e usinas termoeletricas (de complementação), considerando cenários hidrológicos que contemplem a incerteza dos modelos. Para o planejamento do Sistema Interligado Nacional (SIN), um dos modelos utilizados é o PREVIVAZ, mostrado e comentado rapidamente pela Figura 3.7 (Costa et al., 2007).

O PREVIVAZ utiliza diferentes algoritmos de modelagem estocástica dispostos na Tabela 3.2 como Modelos Auto Regressivos (AR), Modelos Auto Regressivos Média Móvel (ARMA), Modelos Auto Regressivos Periódicos (PAR), Modelos Auto Regressivos Média Móveis Periódicos (PARMA), média sazonal (dada pela média mensal), ou média de longo termo (dada pela média anual). Esses modelos, com exceção do “Constante”, são avaliados em três formas distintas: sua forma natural, aplicando uma transformação Box-Cox e aplicando uma transformação Logarítmica (CEPEL, 2015).

Tabela 3.2 – Modelos de Previsão utilizados no PREVIVAZ

Modelo de Previsão	Detalhes
Constante	Média anual
Sazonal	Média mensal
AR(p)	$1 \leq p \leq 4$
ARMA($p, 1$)	$1 \leq p \leq 3$
PAR(p)	$1 \leq p \leq 4$
PARMA($p, 1$)	$1 \leq p \leq 3$

No contexto do PREVIVAZ, os modelos PAR(p) e PARMA($p, 1$) são estruturados, respectivamente, de 5 e 6 maneiras diferentes. Uma dessas modificações nos modelos é nas estruturas de correlação sazonal (podendo ser semanal, mensal, trimestral ou semestral), com seus parâmetros sendo estimados pelos métodos dos momentos. Além dessas 4 maneiras, ambos os modelos PAR(p) e PARMA($p, 1$) podem ser estruturados por uma correlação sazonal mas estimando os parâmetros por uma regressão simples a partir da origem de previsão. O modelo PARMA($p, 1$) possui ainda uma outra variação para essa estimação dos parâmetros, com correlação sazonal, sendo uma regressão simples (CEPEL, 2015).

Nesse modelo, os algoritmos de previsão são testados por validação cruzada (Costa et al., 2007). Como comumente feito, uma parte da série histórica é utilizada para a estimação dos parâmetros enquanto a outra parte é feita para verificação, e conseqüentemente, cálculo dos erros das previsões. Para esses erros, no PREVIVAZ é utilizado o RMSE comentado anteriormente (CEPEL, 2015). Em seguida é feito o contrário, utilizando a parte da série que foi feita a verificação para estimar os parâmetros e utilizando o começo da série para a etapa de verificação. É selecionado como o modelo ótimo aquele com o menor valor de RMSE um passo à frente.

Estudos já mostraram que o PREVIVAZ não é um modelo ideal no âmbito de ser o mais eficiente existente, porém ele já é consolidado internamente dentro dos órgãos e dos outros modelos que o utilizam (Guilhon et al., 2007). Um dos motivos para sua ampla utilização é sua capacidade de representar melhor as vazões observadas do que modelos do tipo ARMA(p, q), do tipo estacionário, que eram usados no planejamento hidrotérmico até 1998 (Maceira et al., 1999).

Após 10 anos utilizando o programa NEWAVE, que utiliza internamente um processo estocástico do tipo PAR(p), dentre outros, para cálculo da energia mensal afluyente, Maceira et al. (2008) agregaram estudos oficiais que o utilizam, juntamente com uma descrição breve do modelo. Os estudos variam desde planejamento operacional e preço da energia até estudos de expansão da matriz energética. Mostrou-se a ampla utilização de modelagem estocástica no contexto do SIN brasileiro até então. Maceira et al. (2018) continuaram o estudo após 20 anos utilizando esse programa, mostrando as devidas atualizações que este teve.

Guilhon et al. (2007) avaliaram o PREVIVAZ em comparação com outros modelos como o SMAP, um MLP (Multi-layer Perceptron), baseado em redes neurais, um modelo de regressão dinâmica e um modelo Fuzzy recorrente para previsões semanais, 1 semana a frente, e diárias, de 1 até 12 dias a frente. O PREVIVAZ, para as três bacias e 5 UHEs avaliadas, esteve sempre entre os piores modelos. Isso foi avaliado pelas métricas NSE, NSElog, MAPE e MAD para cada modelo. Esse estudo também mostrou que há ganho em se utilizar informação da previsão de precipitação à previsão de vazões.

3.2.3 Reservatório Equivalente de Energia (REE)

Proposto por Arvanitidis e Rosing (1970), Reservatório Equivalente de Energia, ou REE, é uma maneira de representar um sistema com múltiplos reservatórios hidrelétricos em uma unidade que consiga exprimir a capacidade energética deles – denominada “energia potencial” em MW. Assim é possível agrupar variados reservatórios em um único, criando um modelo simplificado. Isso pode ser amplamente utilizado para a operação desses sistemas e estudos para planejamentos de operação.

Atualmente são utilizados REEs dentro do programa NEWAVE e DECOMP, seguindo recomendações do CEPEL. Hoje o SIN é representado não apenas por 4 subsistemas (Norte, Nordeste, Sudeste/Centro-Oeste e Sul), mas também por 12 REEs menores (CEPEL, 2018). As informações dos reservatórios agregados nesses 12 Reservatórios Equivalentes de Energia e depois agregados em 4 subsistemas pode ser encontrada no apêndice A (p. 114), juntamente com a localização deles (em latitude e longitude). O apêndice B (p. 121) traz a configuração atual do SIN em 2023. Importante notar que cada subsistema não deixa de ser uma representação de um reservatório equivalente de energia.

A Figura 3.9 mostra esses reservatórios e os subsistemas que os englobam, mostrando também como estão interligados. Anteriormente eram utilizados 9 reservatórios, mas foram manifestados estudos defendendo a utilização desses 12 reservatórios e o ganho operacional disso (MME, 2017). A Tabela 3.3 traz um detalhamento maior informando quantas hidroelétricas individuais, das 166 atualmente existentes, cada REE e cada subsistema representam.

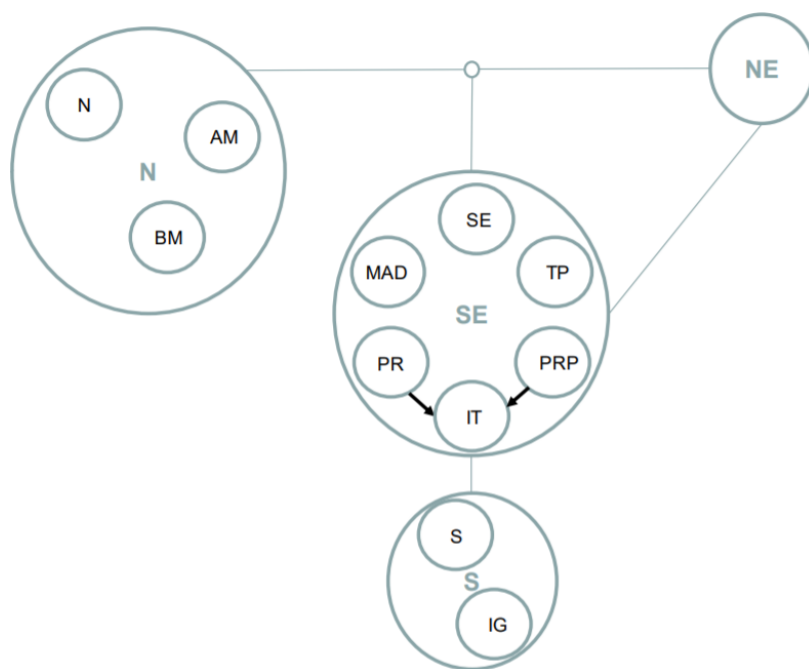


Figura 3.9 Os REEs e os subsistemas do SIN (MME, 2017)

Tabela 3.3 – Número de UHEs por REE e Subsistema

Subsistema	REE	Sigla	Nº de UHEs	
Norte (N)	Norte	N	3	
	Amazonas	AM	5	(10)
	Belo Monte	BM	2	
Nordeste (NE)	Nordeste	NE	10	(10)
	Sudeste	SE	44	
Sudeste (SE)	Madeira	MAD	6	
	Teles Pires	TP	5	
	Paraná	PR	48	(114)
	Parapanema	PRP	10	
	Itaipu	IT	1	
Sul (S)	Sul	S	22	
	Iguaçu	IG	10	(32)
Total	12 REEs	-	166 UHEs	166 UHEs

Pode-se utilizar REE para agregar reservatórios que estão em “cascata”, ou seja, quando várias UHEs são colocadas em sequência em um mesmo rio para aumentar a produção energética desse. Também é possível juntar reservatórios de diferentes rios em um mesmo REE criando reservatórios fictícios para isso. Em ambos os casos a transformação em reservatórios equivalentes é importante na otimização operacional devido a “maldição da dimensionalidade” (Terry et al., 1986).

Esse termo se refere ao fato de que na otimização operacional dos reservatórios, é necessário utilizar o volume com que cada reservatório se encontra. Caso esse volume seja, por exemplo, discretizado em 20 valores (de 5% em 5%) e caso sejam necessários também 20 valores para saber a afluência que virá, para N reservatórios se tornam necessárias 20^{2N} combinações. Portanto um reservatório teria 40 possíveis estados e 5 reservatórios teriam 20^{10} , que são 10 trilhões de estados (Terry et al., 1986; CEPEL, 2019). Fazer isso para todos os reservatórios do SIN possui um custo computacional elevado, tornando essencial essa transformação em REEs.

Reservatórios Equivalentes de Energia são comumente utilizados em outros estudos, especialmente quando avaliando o sistema brasileiro que utiliza dessa simplificação (Lappicy et al., 2021; Simon, 2016; Brandão, 2010). Apesar de não trazerem resultados tão bons quanto aqueles feitos avaliando os reservatórios de forma individuais, REE é uma simplificação aceitável trazendo resultados próximos do que quando analisado cada UHE e podendo trazer um ganho computacional, como mostrado por Brandão (2010).

3.3 VARIÁVEIS EXÓGENAS

Existem modelos que incorporam variáveis exógenas, ou seja, variáveis determinadas externamente e de maneira independente ao modelo, para auxiliarem nas previsões. Exemplos desses modelos são os da família PARX ou modelos de regressão como o RIDGE, que também são capazes de incorporar tais variáveis. Essa variável exógena pode ser qualquer informação que seja relevante e melhore a saída do modelo. Exemplos comuns são a utilização de indicadores de eventos climáticos para auxiliar nas previsões de vazões em escalas mensais ou anuais. Para escalas temporais menores, diária ou semanal, é mais comum o uso de outras informações como valor de precipitações.

Diversos eventos climáticos possuem um impacto no clima, não sendo apenas na escala local. Alguns exemplos desses eventos, que podem causar uma perturbação no ciclo hidrológico de regiões do Brasil são o El Niño Oscilação Sul, ou ENSO (*El Niño South-Oscillation*), o PDO (*Pacific Decadal Oscillation*), o AMO (*Atlantic Multidecadal Oscillation*) e as monções da América do Sul. Para incorporar esses acontecimentos dentro do modelo, pode-se utilizar alguns indicadores que apontam para eles.

3.3.1 Eventos Climáticos de Larga Escala

No Oceano Pacífico, existem diversas medidas e indicadores climatológicos em diferentes regiões e escalas. Algumas dessas utilizadas para previsões de vazões no Brasil e América do Sul são relacionados ao PDO e ao ENSO – foco desta seção.

O ENSO é um fenômeno climático recorrente que envolve mudanças de temperaturas nas regiões central e oriental do Oceano Pacífico equatorial e intensidade dos ventos alísios. Os eventos de El Niño e La Niña são fases extremas do ciclo do ENSO. Esse é um evento climático que causa uma das principais anomalias mensais de TSM no mundo (Deser et al., 2010), sendo então um motivador a sua utilização.

O El Niño é caracterizado por um aquecimento acima do normal na parte leste do Oceano Pacífico equatorial e um enfraquecimento dos ventos alísios (direção Leste-Oeste) levando a uma mudança do regime de precipitações no Brasil. O La Niña é definido como um resfriamento abaixo do normal na parte leste do Oceano Pacífico equatorial e um aumento da intensidade dos ventos alísios, também ocasionando em mudanças no comportamento das chuvas do Brasil.

Um dos principais medidores desses eventos são medidas de TSM em áreas específicas do Pacífico denominadas de regiões Nino 1+2, Nino 3, Nino 4 e Nino 3.4 – essa sendo uma região entre o 3 e o 4. Existem indicadores que utilizam essas medidas, como o ONI (*Oceanic Nino Index*) que é a diferença entre a média móvel de 3 meses de TSM sob a região do Nino 3.4 com a média desses 3 meses dos últimos 30 anos. Existem também outros indicadores do ENSO, como o SOI (*Southern Oscillation Index*) – calculado pela diferença entre a pressão atmosférica entre as cidades de Taiti (Polinésia Francesa) e Darwin (Austrália).

Diferentes estudos na literatura comentam sobre a relação do ENSO com eventos de chuvas e vazões extremas no Brasil, sendo relevantes para avaliar as máximas e mínimas locais em diferentes regiões do Brasil (Costa et al., 2021; Santos et al., 2021; Sahu et al., 2013). Santos et al. (2021) inclusive reconhecem que mesmo o ENSO não sendo necessariamente o principal responsável pelas secas ou cheias na região, ele é um contribuinte de tais situações.

3.3.2 Uso de variáveis climáticas para previsões de vazões na literatura

Existe uma ampla diversidade de indicadores climáticos que podem auxiliar na determinação desses eventos, podendo então ser chamados de preditores climáticos. Esses preditores climáticos são capazes de contribuir na previsão de padrões de chuvas e vazões. Muitos estudos utilizam indicadores, ou preditores, climáticos para previsões de vazões com sucesso (Pham et al., 2021; Moradi et al., 2020; Li et al., 2020; Silveira et al., 2017; Oliveira e Lima, 2016; Lima e Lall, 2010a; Schick et al., 2016; Lima e Lall, 2010a; Lima e Lall, 2010b; Li et al., 2010). Esses indicadores podem vir de diferentes índices climatológicos como, por exemplo, o vento, pressão, temperatura e radiação de ondas longas. Um indicador amplamente utilizado, para previsões de vazões, é a temperatura da superfície do mar (TSM).

A Tabela 3.4 reúne artigos existentes na literatura que encontraram um ganho em utilizar índices climatológicos em previsões hidrológicas, seja para chuva ou vazão. Nota-se que os estudos existem para diferentes escalas temporais, sendo elas diárias, semanais, mensais e anuais, mostrando que há um benefício em serem considerados, independente da escala. Essa tabela traz para cada artigo escolhido, além dos autores e ano de publicação, a escala temporal, as variáveis exógenas utilizadas e os modelos avaliados. Nota-se que existe uso intenso de modelos estocásticos e de aprendizado de máquina (*machine learning*).

Tabela 3.4 – Revisão da literatura sobre uso de variáveis exógenas em previsões hidrológicas com métodos “tradicionais”

Artigo	Ano	Variável	Escala Temporal	Variável Exógena	Modelos usados
Lima e Lall	2010a	Vazão	Mensal	TSM* (NINO3, SACZ)	PAR, PARX, RIDGE
Lima e Lall	2010b	Vazão	Mensal	TSM* (NINO3) e termoclinas (D ₂₀)	Probabilístico
Li et al.	2010	Vazão	Anual	TSM*, PNM**, ROL-S***	MLR, SVM (ambos com e sem <i>bagging</i>)
Schick et al.	2016	Vazão	Diário	Chuva e Temperatura	Regressão
Oliveira e Lima	2016	Vazão	Semanal / Mensal	TSM* (NINO3, SST2), Vento (U1)	PAR, PARX, (+ BMA)
Silveira et al.	2017	Vazão	Mensal	TSM*, Vento	PAR, PARX
Moradi et al.	2020	Vazão	Anual	Chuva, Temperatura, Vazão, TSM* e outros	MLR, ANFIS
Li et al.	2020	Vazão	Mensal	TSM*, Circulação Atmosférica e outros (130)	ENR, SVR, RF, XGB, MSES
Dantas et al.	2020	Chuva	Mensal	TSM* (NINO3, SOI, AMO, PDO, TNA, TSA)	Modelo Aditivo Generalizado
Kayano et al.	2020	Chuva	Mensal	TSM* (PDO, AMO) e sua relação com EN	-
Pham et al.	2021	Vazão	Diário	Chuva, Temperatura, Neve acumulada e outros	MLR e RF
Neslihanoglu et al.	2021	Chuva	Mensal	Temperatura, Umidade Relativa, Nebulosidade	MLR, Estocásticos, SSM, NNETAR, Prophet...

* TSM = Temperatura da Superfície do Mar. ** PNM = Pressão no Nível do Mar. *** ROL-S = Radiação de Ondas Longas de Saída

Os valores de TSM são usados por terem uma relação direta com fenômenos climáticos globais. A relação entre o estado médio (quente ou frio) do PDO e do AMO com o fenômeno de El-Niño e seus impactos nas chuvas da América do Sul foi estudada por Kayano et al. (2020). Avaliar esses fenômenos conjuntos pode trazer conhecimentos que agregam na informação sobre precipitações na América do Sul, algo relevante para estudos de modelagem hidrológica – inclusive na previsão de vazões.

Lima e Lall (2010b) utilizaram o índice do NINO3 e a estrutura de termoclinas, no Pacífico tropical, como indicadores climáticos para auxiliarem nas previsões mensais de vazão de médio e longo prazo (até 20 meses), mostrando a sua eficiência. Em realidade, a vazão foi transformada em energia de maneira parecida a um REE, porém foram agrupadas em quatro grupos com comportamentos hidrológicos similares, ao invés de serem acopladas devido à dependência hidráulica.

Além dos modelos estocásticos comentados neste trabalho, existem diversos outros que tentam incorporar essas variáveis exógenas para previsões hidrológicas (vazão ou chuva). Dantas et al. (2020) utiliza um tipo de Modelo Aditivo Generalizado (GAM) – os de Localização, Escala e Forma (GAMLSS) – na previsão mensal de chuva na Paraíba, Brasil. Fizeram uma clusterização de 45 estações pluviométricas em 5 regiões homogêneas e foi mostrado que os indicadores climáticos utilizados são bons preditores de chuva mensal.

Previsões de vazões de longo termo, como anuais, também podem se beneficiar da incorporação de termos exógenos como visto por Moradi et al. (2020). Estudaram sobre a vazão afluyente a dois reservatórios em uma mesma bacia no Irã, utilizando dados observados de temperatura, precipitação, vazão em estações próximas assim como 29 dados climáticos de relacionados ao oceano, como TSM, ou a relação oceano-atmosfera. Foram selecionados os preditores climáticos por uma análise de componentes principais (PCA – *Principle Component Analysis*) com dois tipos de modelos para previsões, considerando ou não a correlação entre vazões de diferentes locais. As maiores correlações (0.7) encontradas nos indicadores foram para os de taxa de precipitação na superfície e o índice ômega.

Pelo mostrado na literatura, é possível incorporar indicadores climáticos que agreguem nas previsões de vazões para escalas de tempo diárias, semanais, mensais e anuais. Esses

Os modelos estocásticos vistos e ainda utilizados (CEPEL, 2015; Maceira et al., 2018), são datados desde a década de 1970 (Box e Jenkins, 1976). Atualmente existem métodos de aprendizado de máquina que trazem uma alternativa aos modelos estocásticos para previsões de vazões. Esses são, porém, pouco interpretáveis conhecidos também como modelos de caixa preta, ou “*black box*”. Sendo úteis quando se quer ter uma previsão melhor, mas não querendo uma fácil interpretação das relações existentes nele – como é o caso da operação das hidroelétricas.

Nesse contexto, fez-se também um levantamento de artigos pelo *webofscience* para análise do que é feito atualmente na literatura utilizando aprendizado de máquina nas previsões de vazões. Um resumo do encontrado está descrito na Tabela 3.5. Nota-se que não foi notado um algoritmo preferível. Em relação aos métodos mais comuns, destacam-se os métodos de *bagging* (Breiman, 1996a) e *boosting* (Schapire, 1990). Apesar de existirem outros métodos capazes de fazer boas previsões, como algoritmos genéticos e avaliações bayesianas, os métodos de *ensemble* se mostram competitivos a eles.

Bagging (Breiman, 1996a) também é referido como *bootstrap aggregation*, tem como objetivo juntar modelos instáveis (com alta variância) para melhorar as previsões. Se entende por instabilidade quando pequenas mudanças nos dados geram mudanças consideráveis nas previsões (Breiman, 1996a). É possível encontrar diversos exemplos de sucesso em utilizar *bagging* para previsões de vazões (Ribeiro et al., 2020; Schick et al., 2016; Erdal e Karakurt, 2013; Li et al., 2010; Ancil e Lauzon, 2004).

Outro método de *ensemble* é o *boosting* (Schapire, 1990). Exemplos da aplicação desse método para previsões hidrológicas podem ser achadas na literatura (Fu et al., 2019; Botsis et al., 2018; Erdal e Karakurt, 2013; Ancil e Lauzon, 2004). O *boosting* difere de *bagging*, pois é rodado um determinado algoritmo de forma sequencial.

Em relação a como foi feita a comparação entre diferentes métodos, é possível perceber que o critério mais utilizado foi a raiz do erro médio quadrático, RMSE, seguido do R^2 e do erro médio absoluto, MAE (*Mean Absolute Error*). Existe também um uso repetitivo de algum coeficiente de eficiência, apesar de o mais usual ser o de Nash-Sutcliffe, NSE, há também o KGE que possui uma similaridade com ele.

Tabela 3.5 – Revisão da literatura sobre *ensemble learning* aplicado a previsão de vazões

Artigo	Ano	Método	Algoritmos Usados	Comparação por	Melhores Métodos
Anctil e Lauzon	2004	<i>Bagging, Boosting, Stacking, RB e “Stop training”</i>	Redes Neurais	PERS	<i>Ensemble</i> *
Li et al.	2010	<i>Bagging</i> e outros	<i>Support Vector Machine</i> e MLR	MSE, R ²	<i>Bagging</i>
Karakurt et al.	2013	<i>Bagging, Boosting</i> e convencional	Árvores de Decisão e Redes Neurais	MAE, R ² , RMSE	<i>Bagging</i> *
Erdal e Karakurt	2013	<i>Bagging, Boosting</i> e outros	Árvores de Decisão	MAE, R, RMSE	<i>Bagging</i> *
Schick et al.	2016	<i>Bagging</i> e outros	Regressão Linear	MSE	<i>Bagging</i>
Botsis et al.	2018	Estocásticos e <i>ML</i>	Redes Neurais	MAE, NSE, R, RMSE	BNN *
Fu et al.	2019	<i>Boosting</i> e convencional	Árvores de Decisão	CE, EPS, RMSE	<i>Boosting</i>
Ribeiro et al.	2020	Estocásticos, <i>Bagging</i> e outros	Redes Neurais	MAE, NSE, RMSE, R ² , PBIAS, RSR	<i>Ensemble</i>
Li et al.	2020	<i>Ensemble</i> e outros	Árvores de Decisão, Regressão e outros	MAPE, RE, RRMSE, QR	<i>Stacking</i>
Pham et al.	2021	<i>Ensemble</i> e regressão múltipla	Árvores de decisão	MAE, KGE, R ² , RMSE	<i>Ensemble</i>

* Não mostrou melhora significativa a outros métodos de *ensemble learning*

Anctil e Lauzon (2004) avaliam 6 bacias hidrográficas utilizando 5 modelos distintos que possuem, como base, redes neurais para a previsão de vazões um dia a frente. Esses modelos de “*stop training*” e de regularização bayesiana (RB) regulam o algoritmo de treinamento enquanto os modelos de *bagging*, *boosting* e *stacking* afetam a construção do conjunto de treino. Não havendo um modelo ótimo, todos os métodos por agrupamento se destacam e, baseado nesse estudo, os autores recomendam o uso conjunto de “*stop training*” ou a regularização bayesiana com *bagging* ou *boosting*.

Há estudos que comparam certos métodos existentes na literatura com e sem um *bagging* aplicado a eles, como é o caso de Li et al. (2010) que o faz para um SVM (*Support Vector Machine*) adaptado (utiliza algoritmo genético para definição dos parâmetros ótimos) e regressão linear múltipla (MLR). Isso foi feito para a série histórica diária com apenas os meses de dezembro e janeiro (críticos regionais) utilizando informações climáticas (TSM, PNM e ROL-S) e os dados de outubro e novembro para auxiliarem nas previsões. A versão metodológica utilizando *bagging* se mostrou superior a versão “simples”, com o SVM apresentando resultados melhores que o MLR. Notou-se que a relação entre indicadores climáticos e a vazão local possui, aparentemente, comportamento não-linear, algo importante de ser incorporado no modelo.

Outros estudos não avaliam apenas utilizar ou não um método de agrupamento (*ensemble*) em cima de um convencional, mas também comparam diferentes algoritmos como Karakurt et al. (2013) o fizeram. Comparados a uma rede neural convencional, foram avaliados métodos de *bagging* e de *boosting* aplicados a ambas, árvores de regressão e redes neurais – totalizando 5 modelos. Seguindo o mesmo caminho dos outros estudos vistos até agora, os métodos de *ensemble* se mostraram superiores para previsões de vazões diárias. Em cima disso, concluíram também que redes neurais tiveram um desempenho melhor que as árvores de regressão.

Algoritmos baseados em árvores de decisão, utilizando *bagging* e *boosting*, também são avaliados por Erdal e Karakurt (2013) comparando com um modelo de regressão SVR (*Support Vector Regression*) para previsão de vazões mensais. Foram usados dados de uma única bacia utilizando o ano hidrológico para as avaliações feitas. Existiu uma melhora de acurácia ao utilizar esses métodos por agrupamento, mostrando sua constância como bons preditores.

Também podem ser utilizados, os métodos de *ensemble*, para previsões sazonais de vazão (30, 60 e 90 dias) como por Schick et al. (2016) em 66 bacias. Recorreram a comparação de dois modelos, um de regressão e um de *bagging*, com o segundo sendo o mais bem avaliado. Esse ganho de previsão vem à custa de uma menor interpretabilidade do sistema, sendo ideal apenas em certas ocasiões em que o único objetivo é uma previsão pura. Os resíduos neste estudo não apresentaram comportamento iid.

Diferentemente dos outros estudos citados até aqui, Botsis et al. (2018) fazem uma comparação mais semelhante ao proposto com o escopo deste trabalho. Eles avaliam métodos estocásticos (ARMA e ARIMA), possivelmente acoplados a um preditor climático (chuva), assim como métodos de aprendizado por máquina tomando redes neurais como o algoritmo base deles (MFNN, BNN e *boosting*). É avaliada a relação chuva-vazão, estimando em seguida a vazão diária de duas bacias. Todos os modelos apresentaram resultados satisfatórios e próximos entre si, apesar de BNN ter sido o ótimo.

Outras variações de métodos baseados em árvores de decisão também foram testadas, como o MART (*Multiple Additive Regression Trees*) por Fu et al. (2019) para previsão do nível de um rio para previsões de curto prazo (1-3 horas). Essa técnica também pode ser referida como GBT (*Gradient Boosting Trees*). Três modelos de MART foram testados para 5 estações de um mesmo rio. Os modelos conseguem dar uma resposta em 2s apresentando resultados satisfatórios, mostrando também a possibilidade de serem utilizados para previsões de curto prazo e sistemas de alerta.

Há a aplicação dessas técnicas mais modernas também no Brasil com Ribeiro et al. (2020) – que avalia a previsão de vazão mensal em um horizonte de 1, 3, 6 e 12 meses para 5 hidrelétricas pertencentes ao SIN. Esse estudo compara 8 métodos. Desses, 2 são estocásticos (ARIMA e SARIMA), 2 de redes neurais convencionais e quatro de *ensemble* (*bagging* ou MOEL), tendo como base também as redes neurais. O modelo SARIMA apresentou resultados bons para alguns reservatórios, especialmente em um horizonte maior (6-12 meses), enquanto para outros os modelos de redes neurais foram melhores avaliados. Mostraram o ganho também em utilizar um método de *ensemble* em cima desses modelos.

Li et al. (2020) avaliaram diferentes métodos para previsões de vazões mensais utilizando preditores climáticos – dos possíveis 130 eram selecionados 15 para serem considerados nos modelos. Dois dos métodos de *ensemble* (RF e XGB) apresentaram os melhores resultados comparados aos métodos ENR e SVR. É possível melhorar ainda mais as previsões fazendo um *stacking* proposto no estudo (MSES) que reconstrói os dados de treino em uma primeira camada e roda um modelo (o XGB nesse caso) em seguida. O estudo sugere ainda a utilização de previsões meteorológicas para melhorar a acurácia da previsão de vazões mensais, visto que utilizar apenas indicadores climáticos de larga escala e as vazões mensais anteriores pode ser pouco para uma boa previsão.

Um estudo mais recente, Pham et al. (2021), fez previsões diárias, 1 dia a frente, para 86 bacias utilizando o conceito de florestas aleatórias (*bagging*) comparando a modelos de regressão (MLR). Diferente dos estudos anteriores, este analisa bacias que possuem mecanismos predominantes de chuva e/ou degelo. Também são utilizados preditores climáticos – sendo valores de temperatura máxima/mínima e a precipitação em um tempo anterior (ou soma de 3 dias anteriores) entre outros. Os modelos de *ensemble* continuam a se afirmar como promissores nas previsões de vazões em diferentes escalas temporais e para diferentes bacias no mundo. É comentada sobre o impacto de características da bacia na vazão (como declividade e tipo de solo) assim como a possibilidade de trabalhos futuros utilizarem previsão da precipitação para auxiliar no modelo.

4. METODOLOGIA

A metodologia do presente trabalho foi subdividida em três grandes blocos (Figura 4.1) com o primeiro sendo, em sua maior parte, uma caracterização da área estudada. Em suma, a caracterização da área de estudo foi feita obtendo os dados de vazão naturalizada mensal, em m^3/s , das UHEs presentes no SIN. Essa vazão é então transformada em vazão naturalizada e incremental a partir das medições de vazões em cada posto associado a cada hidroelétrica individual. Em seguida é feita uma transformação dessas vazões em Energia Equivalente, transformando de m^3/s em MWmed, de modo a possibilitar o agrupamento dessas usinas hidroelétricas individuais em 12 REEs e 4 subsistemas segundo o ONS.

Por fim dessa caracterização da área de estudo, fez-se uma análise exploratória dessas séries históricas de modo a avaliar o comportamento hidrológico das usinas utilizadas. Em paralelo, também é obtida a série histórica das três variáveis climáticas propostas neste trabalho (U1, SST2 e NINO3) e é estudado o seu comportamento e suas relações com as vazões naturalizadas incrementais e a relação das três variáveis climáticas entre si.

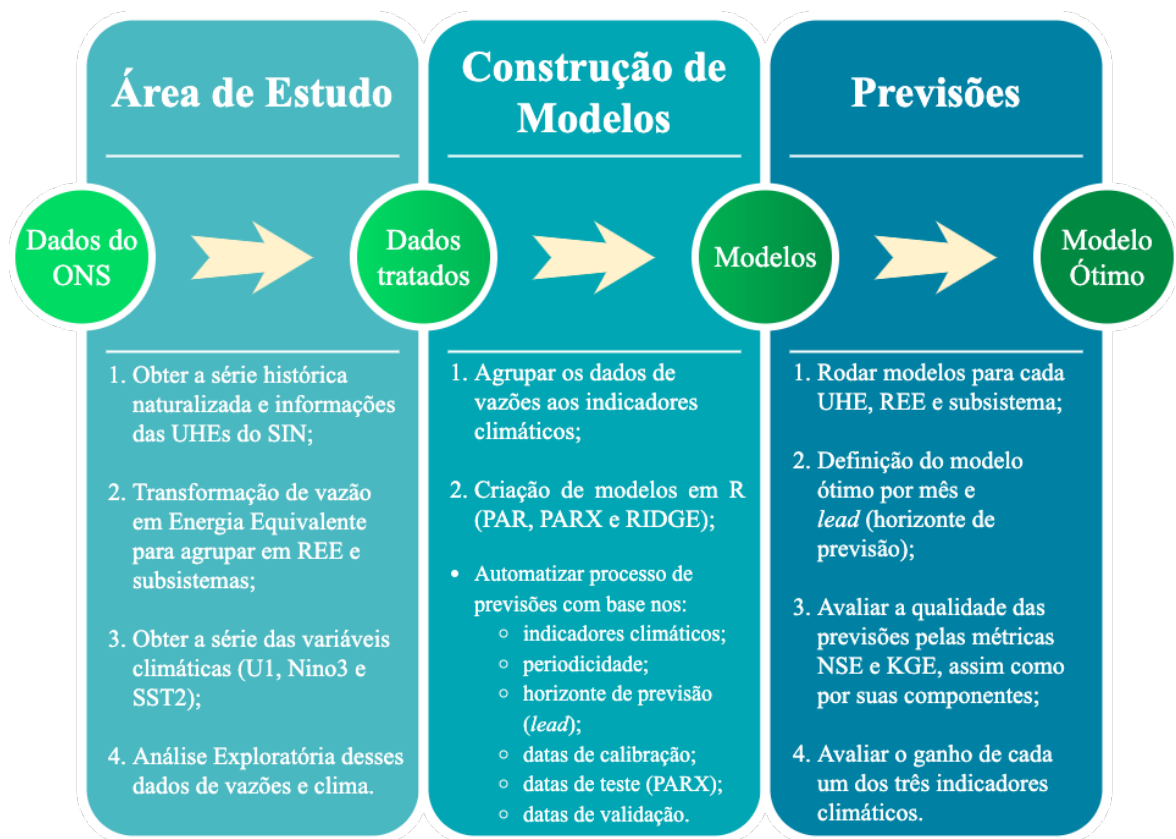


Figura 4.1 Fluxograma geral da metodologia utilizada no presente trabalho

Na seguinte etapa, na construção dos modelos, está a maior parte da programação em R, tendo sido construído um modelo PAR(1), que tem como objetivo imitar o modelo PREVIVAZM, um PARX(1), para utilizar os indicadores climáticos, mas seguindo o comportamento do PAR(1) e um modelo RIDGE que também utiliza os indicadores climáticos, porém define os parâmetros autorregressivos de forma diferente. A rotina foi desenvolvida em R de modo a tentar deixar as previsões de uma maneira mais padronizadas e automatizada, facilitando também futuros trabalhos que busquem avaliar metodologias similares. Essa rotina, inclusive, é mais detalhada pela Figura 4.2 a seguir.

Esses modelos autorregressivos são construídos apenas como sendo sempre de ordem 1, de modo a simplificar e tornar mais rápida as simulações de cada UHE, REE e subsistema. Portanto, para cada mês e cada previsão n meses a frente, é utilizado apenas um coeficiente para o último dado observado. Os coeficientes desses modelos, PAR(1) e PARX(1), são calculados pelo método dos mínimos quadrados, ou LS (do inglês *Least Squares*), mostrada pela equação 3.10 encontrada em seções anteriores.

Já para a regressão *ridge*, os coeficientes são calculados para diferentes valores de gama (λ), definidos pela equação 3.17, testando-os com valores variando de 0 até 100 de 0,05 em 0,05 e em seguida de 100 até 1000 de 1 em 1. Para definir qual λ a ser usado pelo modelo na etapa de validação é utilizado, dentre os valores testados, aquele que retorna a menor validação cruzada generalizada, ou GCV do inglês *Generalized Cross Validation* (Golub et al., 1979). Essa métrica é calculada automaticamente pela função *lm.ridge()*, do pacote *MASS* disponível gratuitamente pelo R.

Para calibrar os modelos propostos, ou seja, para construir as equações do PAR, PARX e RIDGE, com seus coeficientes, foi utilizada apenas parte da série histórica (1949 até 2010). Em cima desses anos, foi ajustado o equacionamento (definição dos coeficientes) que melhor explica essa parte da série histórica, por mínimos quadrados para os modelos PAR e PARX e pela regressão *ridge* para o modelo RIDGE.

É importante notar que apesar de existirem dados desde 1931 para a série histórica de vazão mensal, utilizou-se apenas a partir de 1949 pois os dados dos indicadores climáticos só existem (para os três indicadores) a partir deste ano em específico.

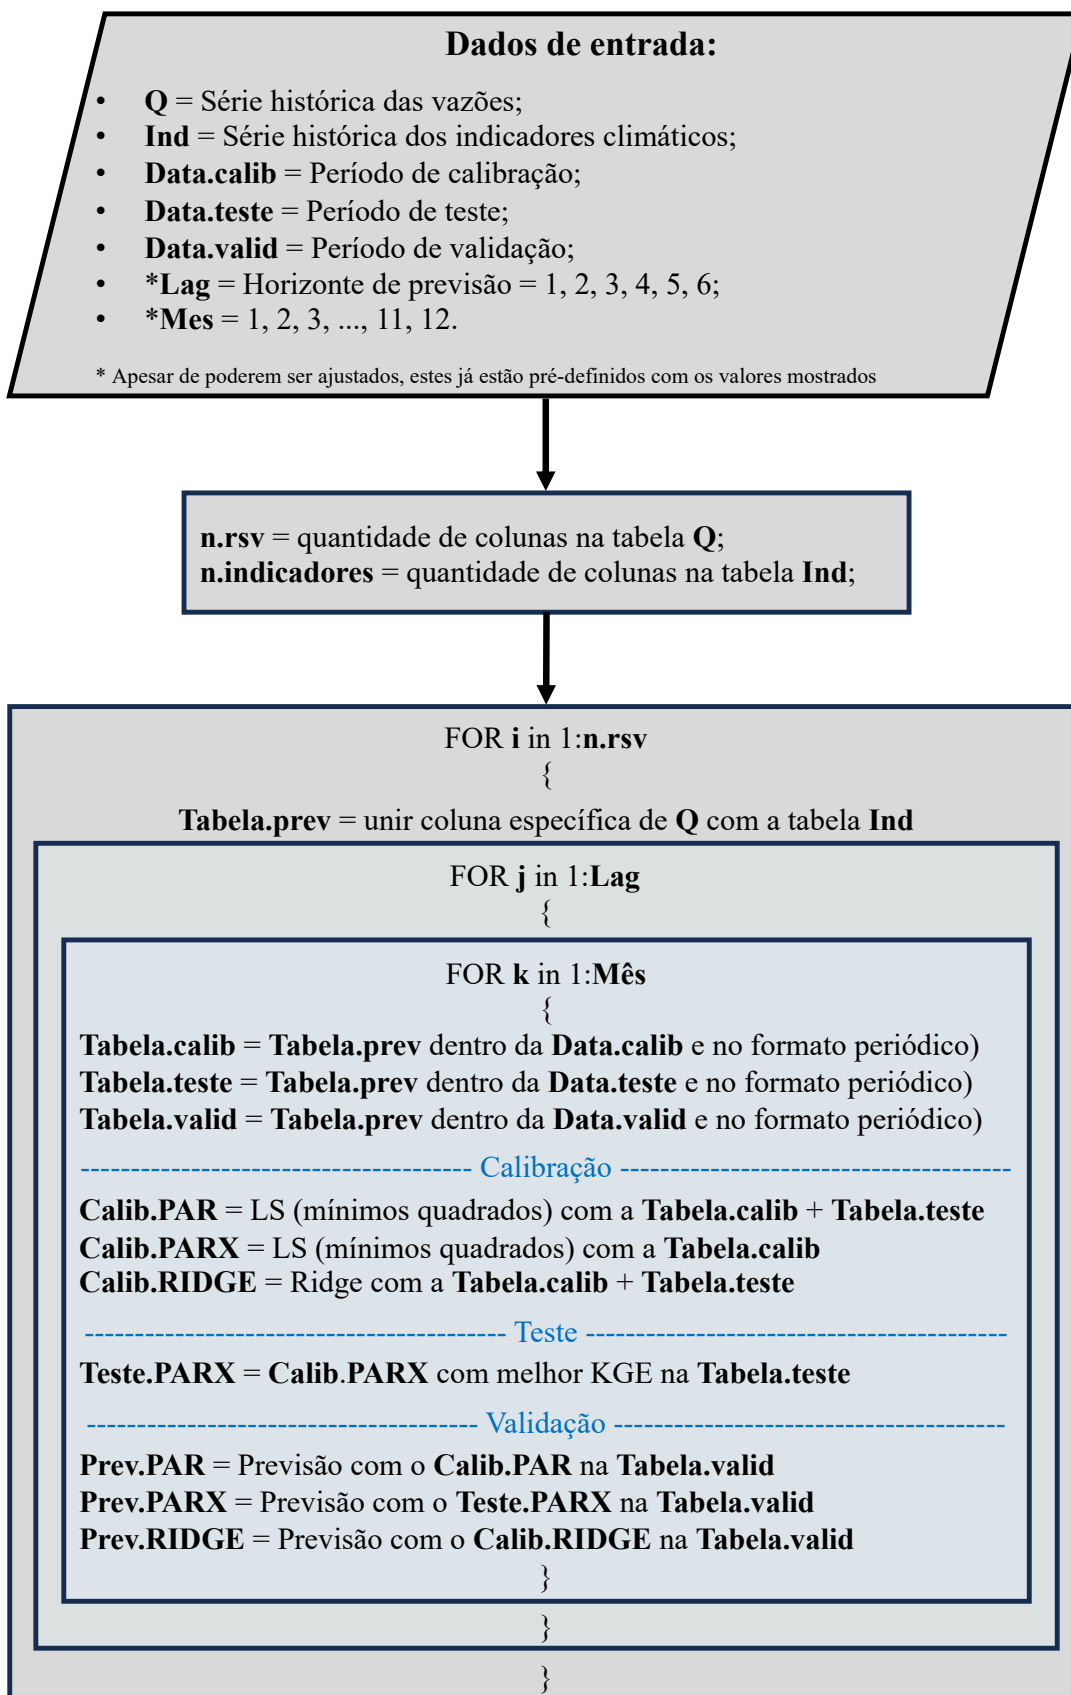


Figura 4.2 Fluxograma da rotina criada em R seguindo a metodologia deste trabalho

No caso do PARX, essa calibração foi feita com os dados de 1949 até 1990, avaliando todas as possíveis combinações de variáveis climáticas (até mesmo sem elas, se igualando a um PAR). Com esses diferentes formatos do PARX, utilizou-se as datas entre 1990 e 2010 para testar os equacionamentos calibrados e definir qual mais adequado para validação, essa seleção de teste foi feita pelo KGE. Por último, na validação, é empregada o restante da série histórica (2011 até 2021) para avaliar a qualidade do modelo, usando os equacionamentos do NSE e KGE (assim como suas componentes individuais), explicados em detalhes no capítulo anterior (equações 3.24 e 3.27).

O fluxograma mostrado pela Figura 4.2 funciona de maneira automatizada, de modo a só ser necessário definir 5 dados de entradas: uma tabela com as vazões de diferentes reservatórios em cada coluna (sendo a primeira coluna as datas), variáveis climáticas (podendo ser qualquer variável explanatória na realidade), e os períodos de calibração, teste e validação (com o de teste sendo utilizado apenas para o modelo PARX). É possível ainda definir variações da periodicidade (variável **Mes**) e horizontes de previsão (**lag**).

Na sequência é feita a avaliação desses modelos em cima das séries históricas (incrementais e naturalizadas para as UHEs individuais e energia afluyente no caso do uso de REE ou subsistemas). Essa avaliação é feita de diferentes maneiras, a principal sendo o que é chamado neste trabalho de “ganho climático”. Esse ganho climático implica a quantidade de cenários em que um modelo que possui informação climática (seja ele o RIDGE ou o PARX) foi melhor do que o modelo sem esses dados exógenos (PAR). Dessa forma, o “ganho climático” não demonstra qualquer informação a respeito do tamanho deste ganho ou da qualidade dos modelos climáticos em si, apenas trazem uma informação a respeito se nas mesmas condições, estes foram melhores ou não que o modelo periódico autorregressivo sem os indicadores climáticos.

Esse ganho climático é importante de ser avaliado pois a proposta deste trabalho não é mostrar que os modelos com dados exógenos sobre o clima são melhores em todos os cenários, apenas mostrar que isso ocorre em alguns casos (alguns meses específicos e para alguns horizontes de previsões). Esse é o objetivo final deste trabalho pois o próprio modelo do ONS, o PREVIVAZM, na realidade roda diversos modelos similares entre si e retorna aquele que o modelo considera como sendo o ótimo. Portanto, uma possibilidade facilmente replicável é de apenas adicionar alguns modelos, ainda similares aos usados atualmente,

porém que usam também indicadores climáticos. Assim o PREVIVAZM poderia, escolher dentre os já utilizados assim como os propostos neste trabalho – ou outros que também utilizem variáveis climáticas para auxiliar nas previsões.

4.1 DADOS UTILIZADOS

Os principais dados utilizados nesse trabalho foram as vazões e os indicadores climáticos. As séries históricas de vazões naturalizadas estão disponibilizadas pelo ONS. Ligada a essa série, também é necessária a configuração do SIN (disponível no apêndice B e pela pelo próprio ONS em: <https://www.ons.org.br/paginas/sobre-o-sin/mapas>) para verificar a posição relativa entre as UHEs (montante ou jusante), de forma a ser possível calcular a vazão incremental. Para fazer a transformação de vazão para energia (de modo a avaliar os REEs e subsistemas do SIN), é preciso informação acerca da altura média de queda das usinas. Esses dados também são disponibilizados pelo próprio ONS para todas UHEs que eles são responsáveis.

Também é necessário obter a série histórica dos preditores climáticos escolhidos (U1, SST2 e NINO3 – comentadas posteriormente). É importante notar que todos esses dados (tanto das vazões quanto dos preditores) são disponibilizados gratuitamente pela internet, o que torna um facilitador da metodologia proposta neste trabalho.

4.1.1 Série histórica das vazões naturalizadas e energia afluyente

O ONS disponibiliza anualmente, pelo portal “sintegre”, uma atualização da série histórica de vazões mensais naturalizadas para todos as usinas hidroelétricas despachadas por ele e presentes no SIN, disponível em <https://sintegre.ons.org.br/> (ONS, 2022). Com base nesses dados, é possível calcular a vazão naturalizada incremental, retirando as vazões de cada usina hidroelétrica das UHEs a montante.

As vazões naturalizadas são aquelas observadas, porém retirando os possíveis efeitos das operações dos reservatórios e adicionando os valores de uso consuntivo a montante e também a evaporação que ocorre nos próprios reservatórios (ONS, 2022). É importante lembrar que tais cálculos envolvem também uma incerteza, sobretudo na espacialização dos usos consuntivos – o que pode afetar os valores.

Para o presente estudo, ao avaliar os REEs e os subsistemas é utilizado o conceito de energia afluyente (em MWmed) ao invés de vazões – é possível utilizar diferentes equacionamentos para atingir isso. O cálculo de energia afluyente mensal de um reservatório i se resume em obter um valor de MWmed a partir das vazões afluentes naturalizadas – isso é feito neste estudo pela equação 4.1. Seja então y_i a vazão naturalizada afluyente do reservatório i em m^3/s , h_i a altura média da queda do reservatório i em metros (calculado pela diferença entre a cota máxima e a cota do canal de fuga, tudo isso dividido por dois) e γ o peso específico da água em N/m^3 .

$$Y_i = y_i * h_i * \gamma * 10^{-6} \quad [\text{Eq. 4.1}]$$

A Figura 4.3 (Lappicy et al., 2021) mostra essa energia natural equivalente para os 4 subsistemas atuais do SIN apenas para uma demonstração visual melhor dos valores – importante ressaltar que o eixo-y dessa figura não é o mesmo para os quatro subsistemas, de modo a conseguir entender melhor o comportamento de cada um deles. É facilmente perceptível a existência de sazonalidade em todos os subsistemas, mostrando então a importância de ela ser considerada nas previsões, sendo preferíveis modelos periódicos ou modelos que capturem a sazonalidade de alguma forma.

Com a Figura 4.3 é possível perceber alguns padrões como, por exemplo, o fato de que o subsistema do SE (Sudeste e Centro-Oeste) é o principal contribuinte para a rede hidrelétrica no Brasil. Nota-se também um pico fora do comum próximo ao ano de 1980 em todos os subsistemas, apontando que provavelmente não se trata de um erro, mas sim de um evento raro que ocorreu em todo o Brasil.

Por último, é importante lembrar que se tem uma série histórica extensa, contendo 91 anos completos de dados sem falhas. É de se esperar então que existe a capacidade dos modelos propostos aqui (PAR, PARX e RIDGE) de serem ajustados sem maiores empecilhos, do ponto de vista de quantidade de dados disponíveis.

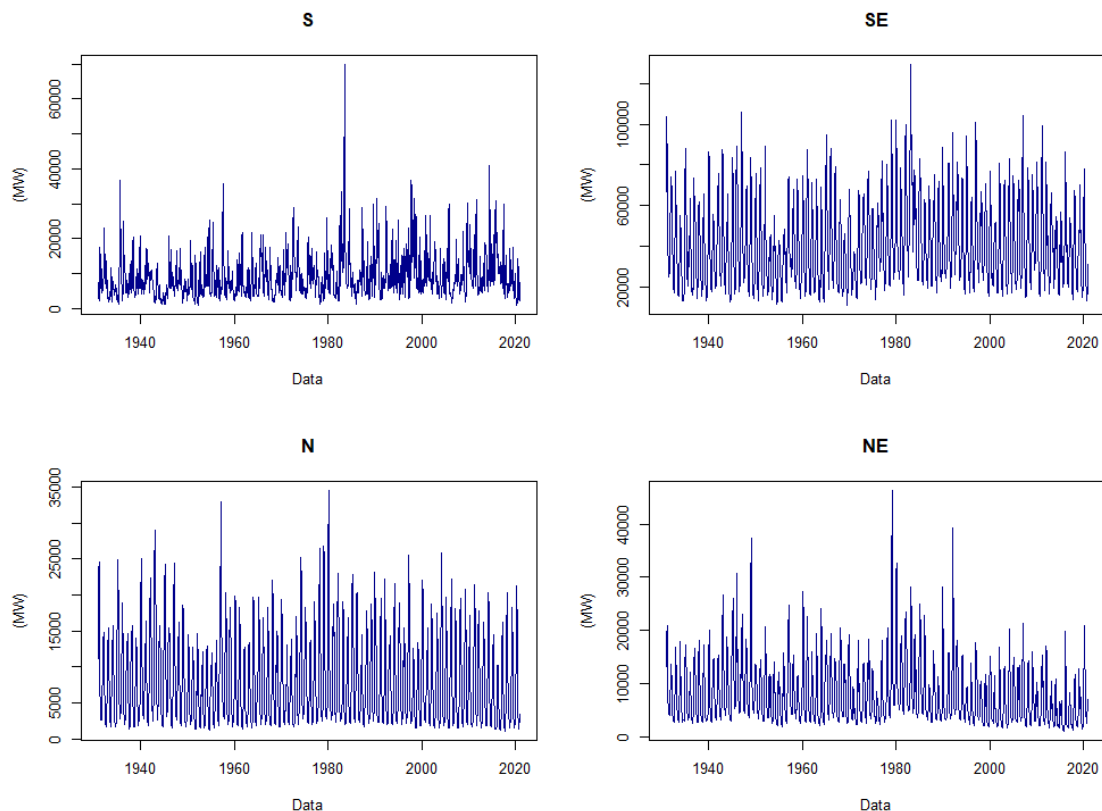


Figura 4.3 Valores de MWmed para os quatro subsistemas em escala mensal (Lappicy et al., 2021)

4.1.2 Preditores climáticos escolhidos e suas séries históricas

Além das vazões mensais, outros dados importantes para construção dos modelos propostos são referentes as variáveis exógenas utilizadas. A partir da revisão de literatura sobre preditores climáticos, percebe-se que existem inúmeros que podem ser utilizados, com um dos mais frequentes sendo em relação a temperatura da superfície do mar (TSM) para auxiliar na previsão de vazões.

Para o presente trabalho, foram utilizadas três variáveis climáticas como uma tentativa de melhorar as previsões, elas sendo os dados de reanálise denominadas pelos índices U1, SST2 e NINO3. Essas três variáveis estão disponíveis pelo IRI (Instituto Internacional de Pesquisa para o Clima e a Sociedade), da universidade de Columbia, disponível online em <<https://iridl.ldeo.columbia.edu/>>. Suas localizações geográficas podem ser vistas pela Figura 4.4 a seguir (Lima e Lall, 2010).




Figura 4.4 Localizações das variáveis climáticas usadas (modificado – Lima e Lall, 2010)

Os dados chamados pelo presente trabalho de U1 são referentes aos ventos zonais na faixa de 700mb e que se encontram entre as latitudes 10°S e 20°S e entre as longitudes 35°W e 50°W. Esses dados, assim como os de U1, também são disponibilizados pelo IRI, podendo ser acessados online pelo link: <<https://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCEP-NCAR/.CDAS-1/.MONTHLY/.Intrinsic/.PressureLevel/.u/>>. Esses dados só existem a partir do ano de 1949 (se estendendo até o momento).

O índice SST2 deste trabalho é referente a anomalias de temperatura média da superfície do oceano pelas coordenadas de latitudes 12°S e 30°S e de longitudes de 20°W e 40°W. Esses dados estão disponíveis pelo IRI em <<https://iridl.ldeo.columbia.edu/SOURCES/.KAPLAN/.EXTENDED/.v2/.ssta/>>. Para os dados de 1861 até 1981, foram utilizadas as temperaturas obtidas por Kaplan (Kaplan et al., 1998) interpolando dados de navios. Enquanto para a série histórica de 1982 até 2023, usaram a metodologia proposta por Reynolds (Reynolds e Smith, 1994), que usa sensoriamento remoto além dos dados tradicionais de navios, mas ainda com as mesmas funções propostas por Kaplan et al. (1998). Para definir as anomalias, utilizaram como base o período entre 1951 e 1980.

Os dados do terceiro índice climático, denominado aqui de NINO3, estão disponíveis pelo IRI em <<http://iridl.ldeo.columbia.edu/SOURCES/.Indices/.nino/.EXTENDED/NINO3/>>. Esse índice se refere aos mesmos tipos de dados que dão origem ao SST2 (dados de temperatura média no oceano no globo), porém em outra localidade geográfica. Dessa forma, essa variável climática contém a série histórica das anomalias de temperatura média na superfície do oceano entre as latitudes 5°S e 5°N e entre as longitudes de 150°W e 90°W. De forma semelhante ao SST2 existem dados desse índice desde 1856 até o presente,

utilizando as propostas feitas por Kaplan et al. (1998) assim como Reynolds e Smith (1994). Esse indicador climático tem direta ligação com os eventos de El Niño e La Niña.

4.2 MODELOS UTILIZADOS

São utilizados três modelos para a previsão mensais das vazões nesse estudo, com dois deles acoplando as variáveis climáticas citadas anteriormente. Não há preditores que sejam, de maneira unânime, os melhores para todas as regiões e todas as escalas temporais. Portanto, para cada UHE, REE e subsistema, assim como para cada mês e horizonte de previsão (*lead time*) determina-se quais preditores mais influentes que devem ser incorporados nos modelos como informações climáticas exógenas.

Primeiramente foi feito, em R (R, 2021), um programa que seja similar ao PREVIVAZM (Costa et al., 2007), denominado aqui apenas de modelo PAR, sem uso de informação climática. Ele é semelhante, mas não idêntico, pois ao invés de reproduzir exatamente o PREVIVAZM é feito nesse trabalho uma simplificação do modelo, sendo utilizado apenas um modelo PAR(1), com a periodicidade sendo mensal. Além disso, utilizou-se apenas o último mês com dado para as previsões, dessa forma para se prever a vazão 3 meses a frente de janeiro, não é feita uma simulação dos meses de fevereiro, março e abril – o modelo PAR(1) proposto aqui utiliza apenas os dados até janeiro para prever diretamente o mês de abril. O coeficiente desse modelo, PAR, é calculado pelo método dos mínimos quadrados (equação 3.10).

Na utilização do modelo PARX, tem-se que as variáveis exógenas são os três indicadores climáticos (U1, SST2 e Nino3). O PARX proposto aqui é similar ao PAR, de modo que é feito apenas um PARX(1), utilizando apenas até a última informação observada para as previsões. Para definição dos coeficientes é feita uma regressão linear, utilizando o método dos mínimos quadrados para seu cálculo. Importante ressaltar que nem sempre as informações climáticas são incorporadas nesse modelo, mas apenas quando é notado um ganho pelo KGE durante a fase de teste. Cada variável pode ser incluída, com a análise sendo feita para cada UHE, mês e horizonte de previsão. Essa rotina também foi feita por completo utilizando a linguagem de programação R de forma a se ter uma rotina automatizada.

Por último tem-se o modelo RIDGE que, similar ao PARX anterior, usa possivelmente as 3 variáveis climáticas, porém utilizando uma regressão *ridge* (equação 3.17) para definir os parâmetros do modelo ao invés de uma regressão linear, não sendo usado, portanto, o método dos mínimos quadrados para definir seus valores. Os valores de λ são feitos para cada reservatório, mês e horizonte de previsão também, sendo testados valores entre 0 (regressão linear) até 100, variando de 0,05 em 0,05 e depois de 100 até 1.000 de 1 em 1. Entende-se neste estudo que existem formas de otimização dessa variável mais recomendadas, essa forma manual é apenas uma maneira de representar o possível ganho de um modelo RIDGE. Também se utilizou o R para automatizar este processo.

É importante ressaltar que nos modelos climáticos propostos aqui (PARX e RIDGE), a informação climática incorporada é sempre de uma defasagem (*lag*) igual ao horizonte de previsão (*lead*) do modelo. Assim, para prever a vazão 2 meses a frente, é utilizada (se existir um ganho) a informação climática de 2 períodos anteriores, mesmo que haja um sinal melhor em utilizar tal preditor climático de 3 períodos anteriores ao invés de 2. Isso é, inclusive, um ponto a ser melhorado para trabalhos futuros – desprender o *lag* das variáveis climáticas do *lead* da previsão feita, buscando a melhor defasagem possível.

4.3 AVALIAÇÃO DOS MODELOS

Para uma avaliação dos diferentes modelos e suas qualidades preditivas, utilizou-se dois indicadores de desempenho. Entre os possíveis métodos, foi selecionado um dos encontrados com maior frequência nos artigos lidos sobre previsões hidrológicas, sendo o NSE. Ele é usado na forma de suas componentes (equações 3.24 a 3.26). Também se optou pelo uso do KGE (equações 3.27 e 3.28), principalmente pelas colocações feitas por Gupta et al., 2009 e Lamontagne et al., 2020 dentre outros críticos do NSE.

Ambas foram escolhidas pelo amplo uso na literatura e para mostrar a diferença em utilizar esses dois indicadores. Além disso, aqui foram calculadas essas métricas juntamente com suas componentes individuais (α , r , β_{NSE} e β_{KGE}). Isso também traz um aspecto interessante dos modelos avaliados, mostrando em qual aspecto as variáveis climáticas conseguem auxiliar nas previsões (na correlação, no viés ou na variância das simulações).

A avaliação dos modelos é feita, primeiramente, em três formatos separados. Primeiramente as séries históricas, seja de UHE individuais, REE ou subsistemas, são agrupadas para cada mês existente da previsão (agrupando então previsões com diferentes *lead times*). Com isso, se espera obter informações a respeito da sazonalidade existente em utilizar os dados climáticos propostos. A avaliação é feita então de forma objetiva, contando para cada UHE (REE ou subsistema) qual foi o modelo que obteve o melhor valor de cada métrica ou componente específica – esse seria o que chamamos de “ganho climático”. Não levando em consideração, portanto, o tamanho desse ganho ou a qualidade geral do modelo.

De maneira semelhante, em seguida as séries históricas são agrupadas (diferenciando ainda cada UHE, REE ou subsistema) para cada horizonte de previsão (1 até 6 meses a frente), unindo então os diferentes meses. O mesmo “ganho climático” é avaliado aqui (qual modelo melhor para cada UHE, REE ou subsistema em questão e para cada *lead time*). Com esse agrupamento, é esperado obter informações a respeito do modelo em si. É de se esperar que a qualidade dos modelos decaia com o aumento do horizonte de previsão, assim, caso isso não ocorra, é necessário buscar fatores que possam justificar tal comportamento.

Por último, não é feito agrupamento algum. Assim para cada mês e horizonte de previsão específico, se avalia o “ganho climático” (quantas UHEs, REEs ou subsistemas tem cada modelo como o melhor possível para cada mês e *lead time*). Dessa forma, tem-se uma informação mais detalhada das previsões, porém mais numerosa (tem-se 157 UHEs, 12 meses e 6 horizontes de previsões diferentes).

Após avaliar esse comportamento geral das previsões, duas novas análises são feitas. Com a primeira sendo uma avaliação da distribuição numérica dos valores de cada métrica. É feito, então, um gráfico de densidade para cada métrica e componente avaliada. Isso ajuda a entender melhor como o uso de informações climáticas impacta as métricas de qualidade do modelo. Assim, independente do mês e horizonte de previsão, é possível obter uma noção do impacto na variação dos valores numéricos de fato (e não apenas se um modelo é melhor ou não que o outro).

Similarmente a esse gráfico de densidade, é feito um gráfico de densidade mostrando o ganho numérico de se utilizar os indicadores climáticos, ou seja, numericamente quanto que os modelos RIDGE e PARX melhoram o modelo PAR (apenas quando essa melhora existe).

Assim, pode-se ter um melhor entendimento do tamanho deste ganho. Algumas medidas específicas desse ganho como média, valores máximos e valores mínimos (dentre outros), são destacadas em tabelas para facilitar a verificação desses números.

Após essas avaliações numéricas do “ganho climático”, é feita uma análise espacial desse ganho. Avaliando a porcentagem de cenários (os meses e horizontes de previsão) que cada UHE, REE ou subsistema em que os modelos RIDGE ou PARX (com informação climática) são superiores ao total de cenários feitos (72 no total – referente aos 12 meses e 6 *lead time*). Esses mapas são realizados usando todos os indicadores climáticos recomendados pelo modelo ótimo (podendo utilizar 1, 2 ou os 3 dados climáticos a depender da UHE, mês e horizonte de previsão).

Os últimos mapas desenvolvidos são uma tentativa de avaliar o impacto que cada indicador climático (U1, SST2 e NINO3) possui nas previsões. Isso é feito forçando os modelos climáticos a utilizarem apenas um dos indicadores e em sequência avaliando o “ganho climático” (porcentagem dos cenários em que o modelo climático é superior ao PAR) apenas com esse indicador específico – em seguida repetindo isso para os outros 2. Assim, é possível ter um melhor entendimento dos locais em que cada dado climático é mais efetivo assim como o tamanho do efeito em relação aos outros indicadores.

5. ÁREA DE ESTUDO

O presente trabalho tem como foco otimizar as previsões das vazões nos reservatórios que compõem o SIN, operado pelo ONS, em todo o Brasil. O Brasil é subdividido pela Divisão Hidrográfica Nacional (CNRH, 2003) em 12 regiões hidrográficas (diferente que bacias hidrográficas), essas sendo a região hidrográfica Amazônica, Atlântico Leste, Atlântico Nordeste Ocidental, Atlântico Nordeste Oriental, Atlântico Sudeste, Atlântico Sul, Paraguai, Paraná, Paranaíba, São Francisco, Tocantins-Araguaia e Uruguai – Figura 5.1.

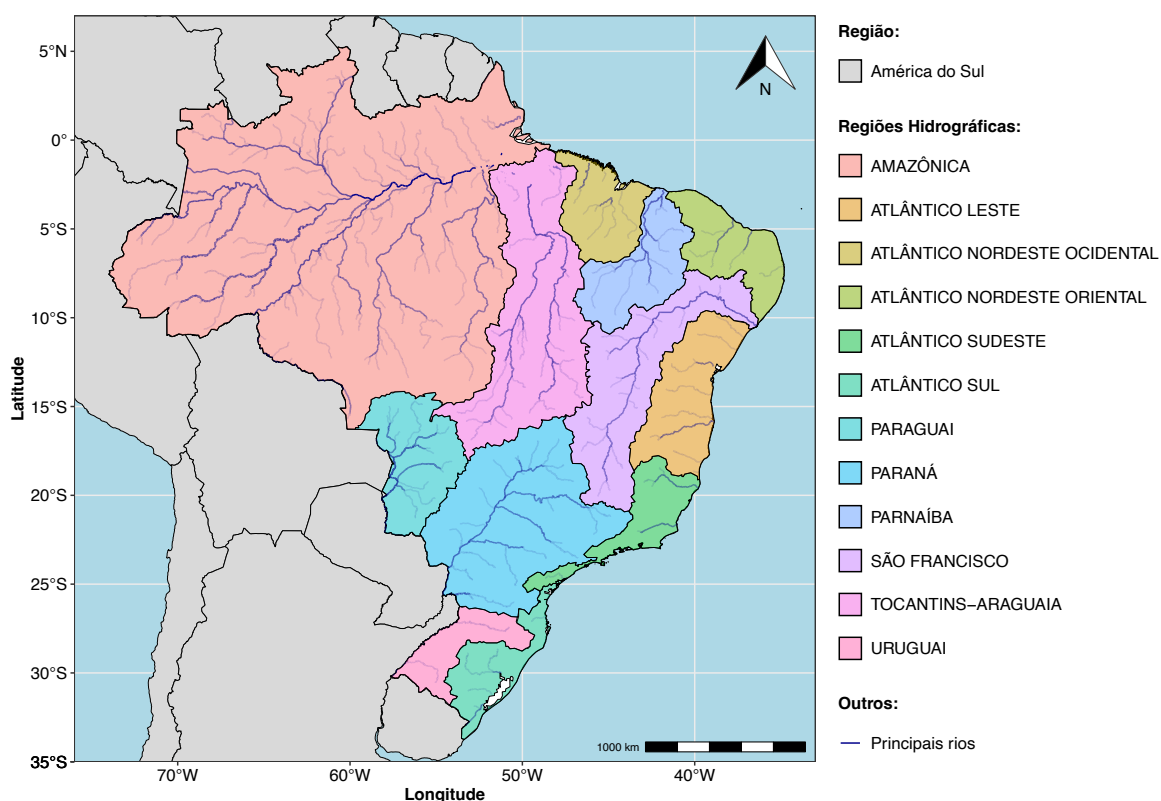


Figura 5.1 Reservatórios com as bacias hidrográficas do Brasil

Para atingir o objetivo geral, foram obtidos os cadastros e todos os dados históricos observados de todas as UHEs despachadas pelo ONS (ONS, 2020). Com esses cadastros, que possuem informações como latitude e longitude, cada UHE foi georreferenciada e plotada em um mapa também contendo as 12 regiões hidrográficas do Brasil. Além disso, é possível agrupar os reservatórios por subsistemas (Figura 5.2) ou pelos 12 reservatórios equivalentes de energia (Figura 5.3) destacando o centroide desses subsistemas ou REEs e tornando as UHEs individuais um pouco de translúcidas nos mapas.

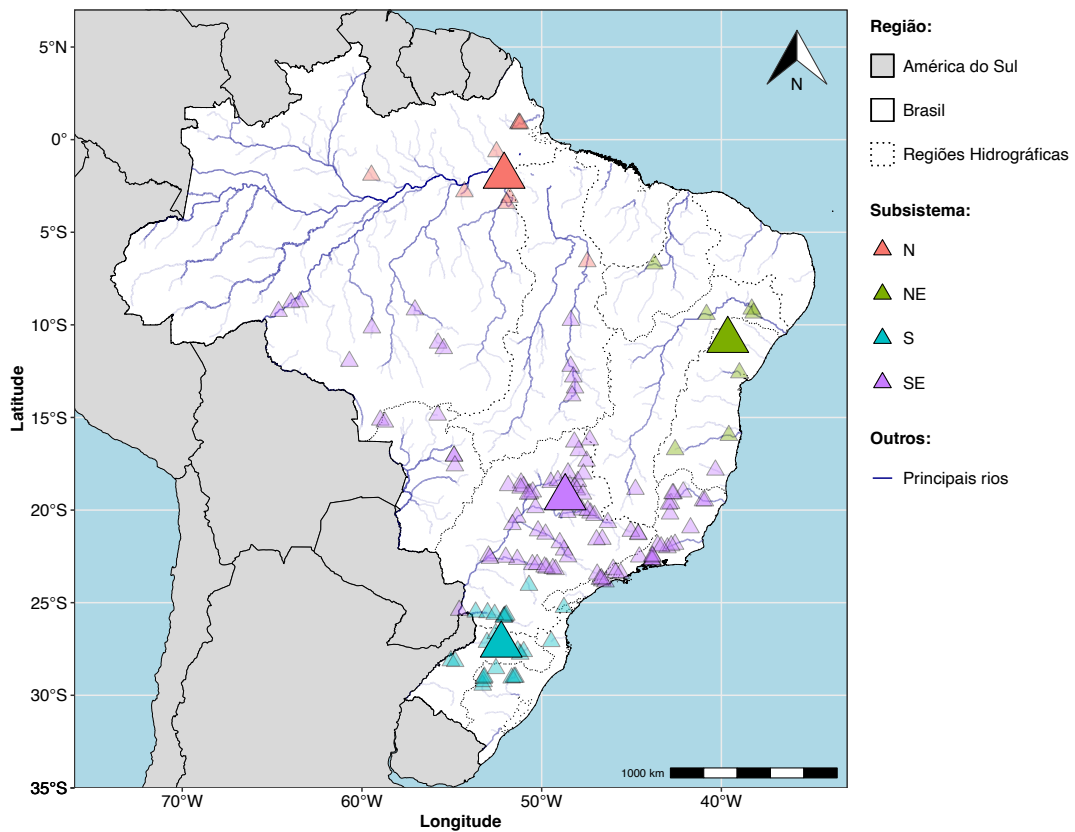


Figura 5.2 UHEs com as bacias hidrográficas do Brasil por subsistema

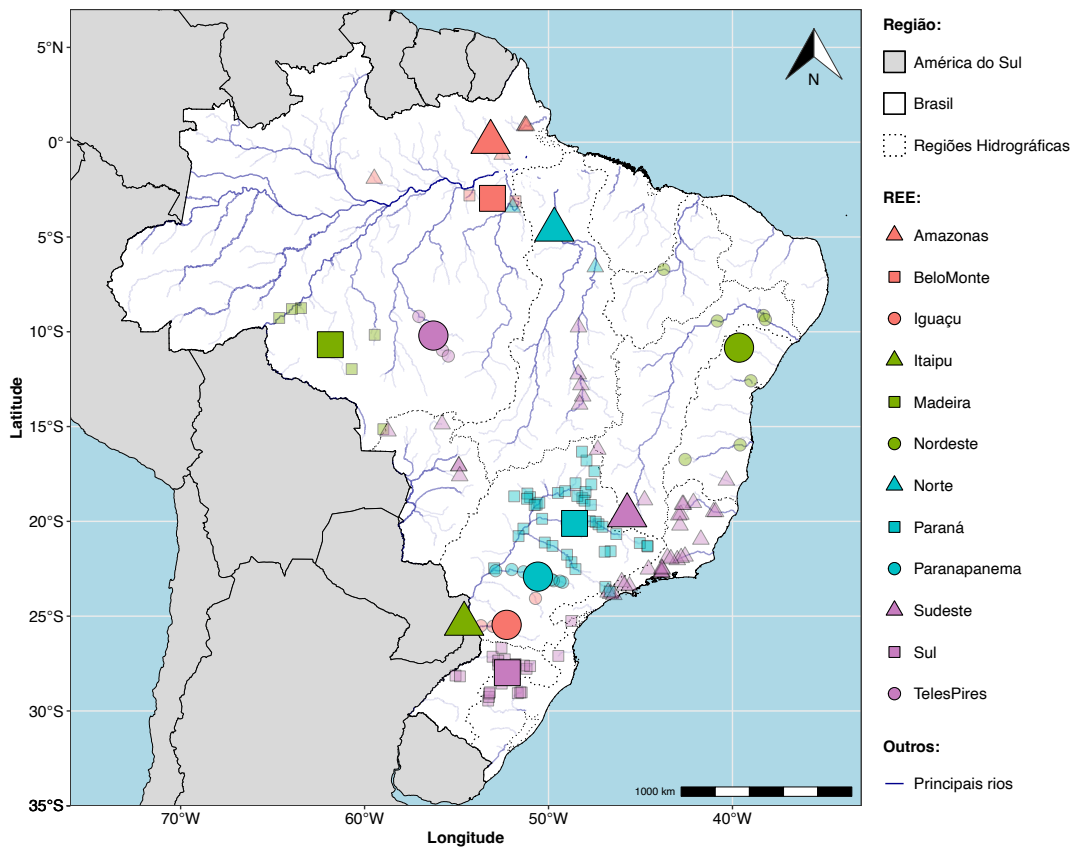


Figura 5.3 UHEs com as bacias hidrográficas do Brasil por REE

Pela análise exploratória mostrada na Figura 5.2 e na Figura 5.3, observa-se que existem 167 estruturas do SIN despachadas pelo ONS. Existe uma a mais do que pela Figura 3.9 ou Tabela 3.3 pois uma UHE em específico ainda não está construída e operacional. Dessas 167, 74 são usinas com reservatórios, 89 são usinas a fio d'água e 4 são usinas de bombeamento. Porém nem todas as 167 são utilizadas nas previsões e análises feitas nesse estudo, isso porque algumas UHEs possuem vazões naturalizadas incrementais iguais a zero (por estarem em cascata, por exemplo). Dessa forma, apenas 157 UHEs são utilizadas, quando avaliando as hidroelétricas individuais.

A quantidade de usinas ou reservatórios por região hidrográfica brasileira se encontra de maneira detalhada no apêndice A (p. 114), juntamente com diversas tabelas contendo todas UHEs separadas por REE detalhando cada usina hidrelétrica com sua posição geoespacial (latitude e longitude) e no apêndice B está a configuração do SIN para 2023 (p. 121). Essa tabela no apêndice A também possui informação sobre a estacionariedade da série observada da UHE em questão – isso é abordado nos resultados a seguir.

6. RESULTADOS

Os resultados estão separados em quatro partes. A primeira é uma análise exploratória das usinas hidrelétricas, a respeito da estacionariedade das séries históricas e a escolha das séries utilizadas. Em segundo é feita uma análise das três variáveis climáticas escolhidas para auxiliar nas previsões. Na sequência são mostrados os principais resultados obtidos para as previsões em todas as séries utilizadas, sendo comentado sobre os melhores modelos, a posição especializada de cada UHE com ganho em utilizar informações climáticas e o ganho em si existente na utilização de tais variáveis exógenas. Por último, essa avaliação também é feita para os 12 REEs e para os 4 subsistemas do SIN, utilizando o conceito de energia equivalente.

6.1 ANÁLISE EXPLORATÓRIA DAS UHEs

Similar ao feito na seção 5 (ÁREA DE ESTUDO), aqui foram feitas algumas análises mais específicas de cada UHE. Primeiramente, realizou-se uma análise da estacionariedade das estações pelo teste do KPSS. Caso a série histórica não seja estacionária pelo teste, é realizada uma diferenciação na série (equação 3.8). Se a série for estacionária com base nessa diferenciação ela é denotada como “estacionária com ∇^1 ”, com ∇^1 sendo a diferença necessária para estacionariedade.

A espacialização dessas estações acerca a estacionariedade delas está presente na Figura 6.1. Nota-se que das 157 séries históricas das UHEs avaliadas, 40 possuem uma série histórica estacionária enquanto as outras 117 são estacionárias apenas após uma diferenciação na série. Dessa forma, nenhuma das séries é não estacionária, depois que feita até uma diferenciação nos dados. Essa informação está também no APÊNDICE A – DETALHES DOS REES E SUBSISTEMAS.

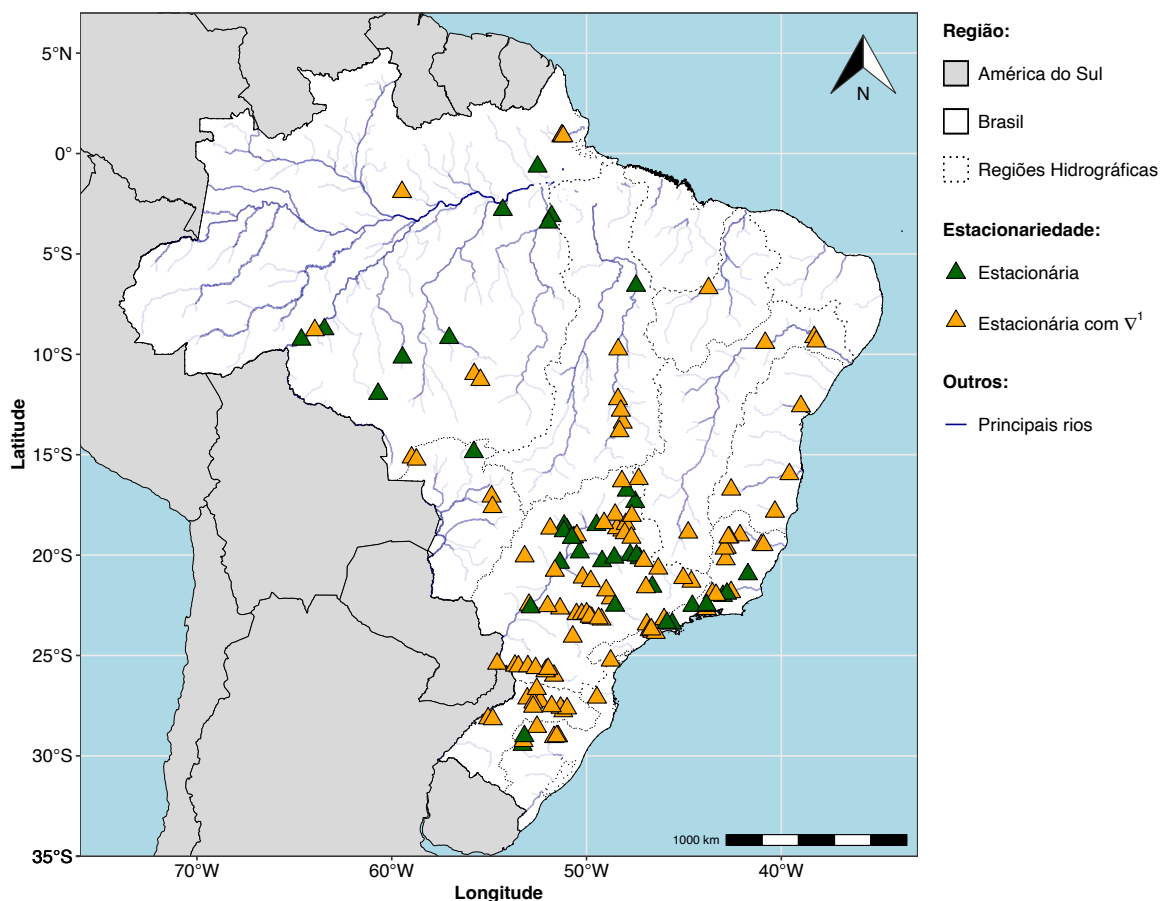


Figura 6.1 Estacionariedade das UHEs pelo teste do KPSS

A última análise preliminar realizada é em função da sazonalidade da série histórica. Ao separar as UHEs em subsistemas e REEs, é calculada a relação entre sua Q_{95} mensal e a vazão média histórica para cada mês. Isso é feito como uma tentativa de normalização das vazões, de modo a que a comparação entre diferentes hidroelétricas se mantenha em uma faixa de valores comparável, podendo ser visto visualmente as diferentes sazonalidades, como épocas de cheias e secas (Q_{95} maiores ou menores que a média histórica). A Q_{95} foi calculada pelo método de Weibull (Maidment, 1983). Isso da uma informação em relação a sazonalidade das estações e se é possível perceber comportamentos similares em um mesmo subsistema (Figura 6.2) ou um mesmo REE (Figura 6.3). Para avaliar essa sazonalidade, se utilizou apenas as 157 usinas comentadas anteriormente.

Alguns padrões podem ser notados avaliando os subsistemas (Figura 6.2). Percebe-se que os subsistemas Norte, Nordeste e Sudeste possuem uma sazonalidade mais bem definida do que o subsistema Sul – do qual possui duas épocas de cheias em um mesmo ano, de maio a julho e de outubro a janeiro. O subsistema Nordeste é o qual as usinas mais se comportam

parecidas entre si, tendo claramente meses de cheia (dezembro – abril) e de seca (junho – novembro). Apesar do Sudeste também ter um comportamento aparentemente similar entre as UHEs, a quantidade de usinas mostra que existem algumas (poucas) que possuem comportamento pouco diferente.

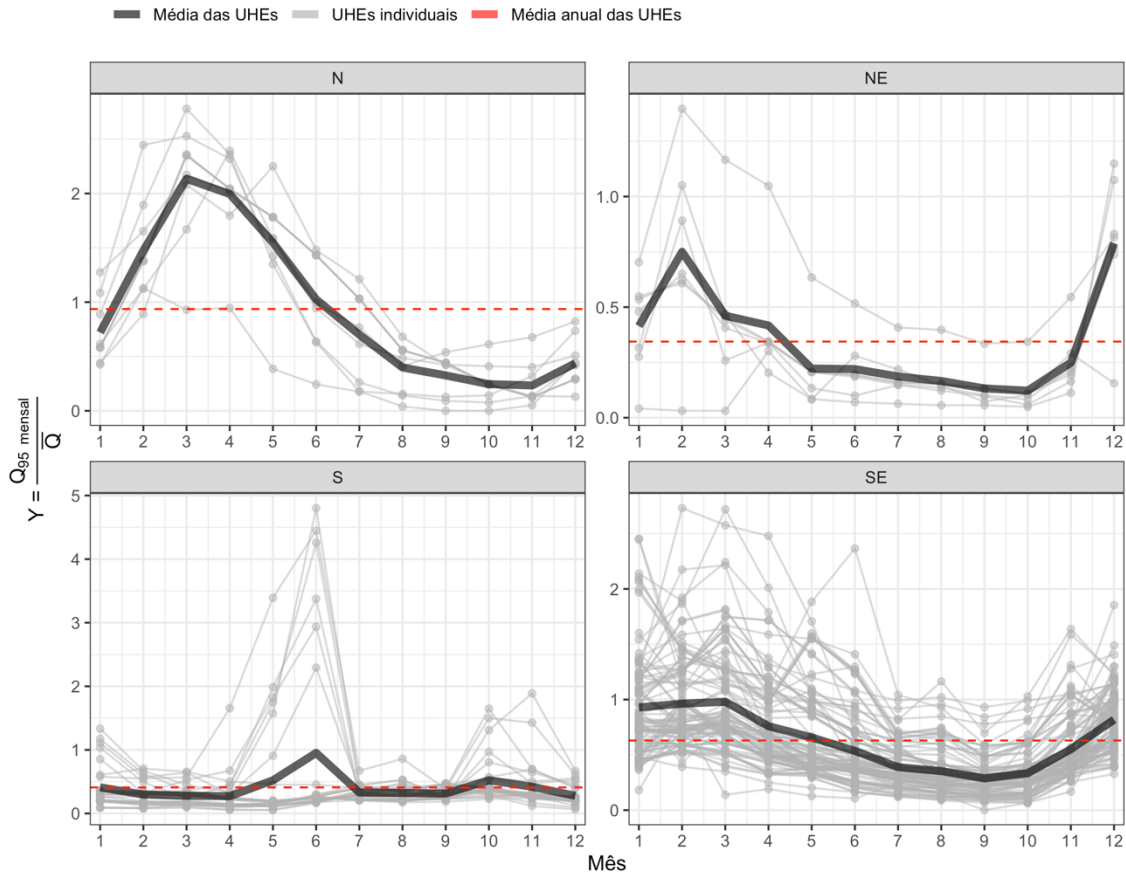


Figura 6.2 Relação entre a Q_{95} mensal e a \bar{Q} histórica por UHE e subsistema

Quando agregando as UHEs por REE, Figura 6.3, se nota de maneira mais clara os comportamentos “diferentes” de algumas usinas vistas na Figura 6.2 de forma mais evidente. As UHEs pertencentes aos reservatórios equivalentes de energia “Amazonas”, “Madeira”, “Nordeste”, “Norte”, “Paraná”, “Sudeste” e “Teles Pires” apresentam forte sazonalidade que pode ser determinada visualmente. Enquanto usinas do “Iguaçu”, “Itaipu”, “Paranapanema” e “Sul” apresentam comportamento mais complexos, no qual os meses de seca e cheia não são tão facilmente separados. Inclusive existem hidroelétricas no Sul com dois períodos chuvosos no ano (notados também na análise pelos subsistemas), o que dificulta a sazonalidade desses locais.

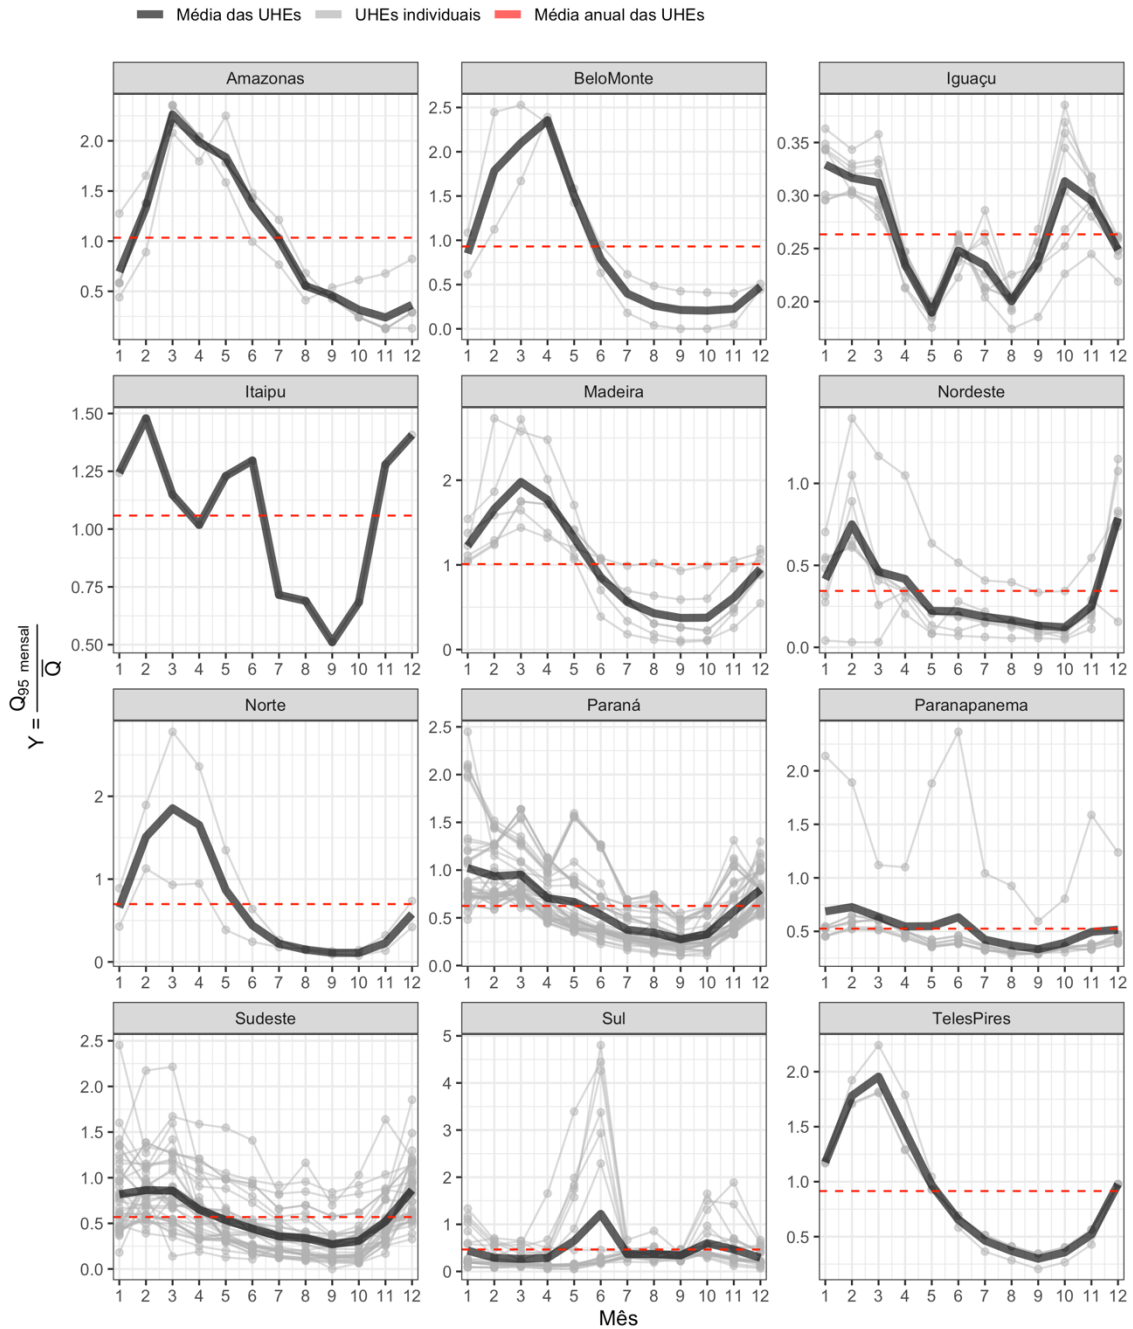


Figura 6.3 Relação entre a Q_{95} mensal e a \bar{Q} histórica por UHE e REE

6.2 VARIÁVEIS CLIMÁTICAS

As variáveis climáticas usadas foram descritas na metodologia e são denotadas como “U1”, “SST2” e “Nino3”. Uma primeira etapa que precede os resultados dos próprios modelos é na verificação de que as variáveis são adequadas como auxiliares nas previsões das vazões. Para isso, foram feitas duas análises de correlações. Uma sendo entre as variáveis climáticas e as vazões enquanto a outra é entre as próprias variáveis climáticas.

As variáveis preditoras a serem incluídas em um modelo devem possuir duas características principais. Primeiramente devem ter uma correlação com a variável que se deseja avaliar, nesse caso, a vazão naturalizada incremental das UHEs. Além disso, é importante garantir que não exista uma alta correlação entre as variáveis preditoras escolhidas para evitar uma queda no desempenho dos modelos.

A existência de correlação entre a vazão naturalizada incremental e as variáveis climáticas é analisada aqui a partir da correlação cruzada (CCF, do inglês *Cross Correlation Function*) entre cada uma das três variáveis climáticas e as vazões naturalizadas incrementais de cada UHE, mostrada pela Figura 6.4.

É importante ressaltar que, nesses gráficos, os valores no eixo-x são discretos, existindo nele apenas 13 números inteiros (-12, -11, ..., -1, 0). Para facilitar a visualização desses pontos (que possuem um mesmo valor de *lag* no eixo-x), criou-se um ruído nos valores de x, de modo que ainda sejam facilmente reconhecíveis os intervalos entre os possíveis valores. Outro fator importante é que esses pontos são para todos os meses em todas as hidroelétricas. Espera-se que haja meses específicos com sinal mais forte que outros, e não se espera que todas as hidroelétricas utilizem todas as variáveis exógenas em todos os meses de previsão. Assim, a correlação cruzada aqui, quando avaliada de modo geral, tende a subestimar o ganho que algumas hidroelétricas podem ter em meses específicos.

Nota-se a existência de uma correlação significativa (fora dos limites em azul e com uma coloração verde) em diferentes *lags* de até 12 meses. Essa correlação é maior quando se aproxima do *lag* 0, o que é de se esperar, porém existindo altas correlações para valores anteriores. O próprio índice SST2 possui correlações estatisticamente significantes até para valores de 12 meses anteriores. A quantidade de pontos estatisticamente significantes, ou seja, que estão acima da linha azul pontilhada definida, nos *lags* entre -3 e 0 está destacada em cada gráfico.

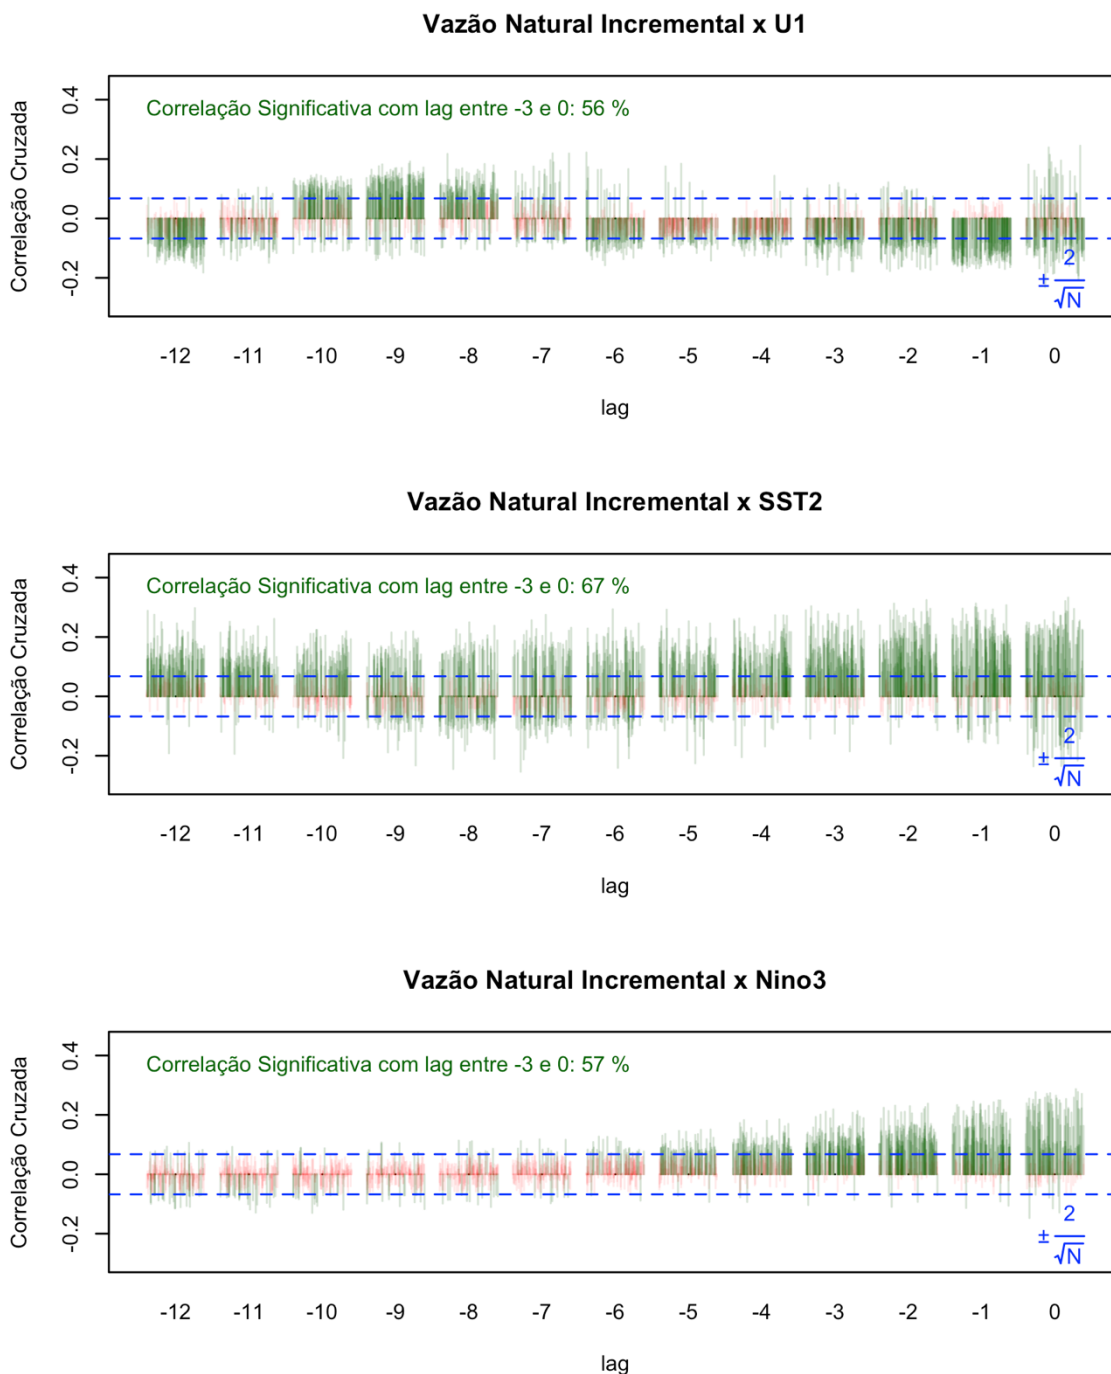


Figura 6.4 Correlação Cruzada entre as vazões e os preditores climáticos

A variável climática SST2 é a que possui correlação mais forte com as vazões, tendo valores de até 0,42 e com 67% dos pontos de todas as UHEs dos *lags* entre -3 e 0 estatisticamente significantes (fora do intervalo azul pontilhado). Essas correlações são, em sua maioria, positivas e, além disso, essa variável exógena demonstra uma persistência da correlação para valores bem anteriores a vazão, sendo perceptíveis para *lags* de até 12 meses.

Para o NINO3 o impacto é menor, com correlações de até 0,32 com 57% dos pontos sendo estatisticamente significantes. Esse indicador começa a ter menor efeito a partir do *lag* de 5 meses, possivelmente não havendo ganho em previsões mais longas. As correlações cruzadas para essa variável climática são, similarmente ao SST2, positivas.

Por último, a variável U1 é a que possui menor impacto, mas ainda sim possui correlações cruzadas com valores de até 0,24 e com 56% dos pontos sendo significantes (lembrando que aqui são avaliadas todas UHEs e todos os meses sendo que não necessariamente todos utilizariam esse indicador). A correlação da U1 acompanha também a sazonalidade da série, com a maior parte das correlações cruzadas mais recentes sendo negativas (diferentemente das outras variáveis climáticas), se tornando mais positivas e depois retornando para valores negativos a medida que os *lags* vão aumentando em módulo.

A Figura 6.5 traz a correlação entre as próprias variáveis exógenas utilizadas (U1, SST2 e Nino3) em diferentes *lags*, de modo a verificar a independência entre elas. Na imagem, a diagonal superior mostra apenas a coloração dessa correlação (há uma legenda indicando a ordem de grandeza dessas cores), com a diagonal inferior trazendo os valores numéricos. Como apenas as relações entre diferentes índices são de interesse nessa análise, apenas esses estão com os valores destacados (diagonal inferior). Na diagonal superior, essas relações (entre diferentes índices) são destacadas por uma linha preta e pelas letras “A”, “B”, e “C” indicando as quadrículas relevantes.

É de se esperar que exista uma correlação nos *lags* de uma mesma variável climática, o que estamos interessados é verificar a possível correlação entre as diferentes defasagens dos índices U1, Nino3 e SST2. Não é notada nenhuma correlação significativa, o que, *a priori*, demonstra que as variáveis escolhidas trazem, possivelmente, ganhos de informação diferentes quando relacionadas a vazões.




Figura 6.5 Correlação das variáveis climáticas escolhidas e defasagens t

De uma maneira geral, notou-se uma relevância em utilizar as três variáveis exógenas propostas por terem uma correlação cruzada significativa com as vazões naturalizadas incrementais das UHEs avaliadas. Além disso, tais variáveis se mostraram com diferentes comportamentos na correlação cruzada e com baixas correlações entre si, sendo, portanto, um bom indicativo na escolha dos preditores.

6.3 QUALIDADE DAS PREVISÕES

Para avaliar a qualidade das previsões, foram selecionadas as métricas propostas na metodologia, sendo elas o NSE e KGE. O NSE foi avaliado pelo próprio valor (equação 3.24) assim como pelas suas 3 componentes: r , α (alpha) e β_{NSE} (Beta NSE), como escrito pelas equações 3.25 e 3.26. Isso é feito para que seja possível conferir com maiores detalhes em qual parte está o ganho de utilizar as variáveis climáticas. Pelos problemas existentes

com essa métrica, optou-se por trazer também os valores de KGE (equação 3.27), com suas três componentes (o r e o α são o mesmo, mas existe um beta, β , diferente descrito pela equação 3.28 e chamado aqui de β_{KGE}).

A avaliação dessas 2 métricas (NSE e KGE) descritas por suas 4 componentes (r , α , β_{NSE} e β_{KGE}) foram feitas nessa seção. Os dados simulados foram avaliados de três formas distintas:

- agregando todos os horizontes de previsão (1 a 6) juntos para avaliarmos as métricas, mês a mês;
- agregando todos os meses juntos, para que as métricas sejam avaliadas por horizonte de previsão, também chamados de *lead times*;
- sem essa agregação, trazendo, portanto, uma informação mais detalhada do comportamento específico das UHEs.

Além da avaliação a partir das séries de vazões incrementais e naturalizadas, agrupando, em cada UHE, pelos meses ou pelos diferentes horizontes de previsão, também foi feita uma avaliação do comportamento espacial das hidroelétricas. Isso foi realizado analisando espacialmente os resultados obtidos na seção 6.3.1 a seguir. Em seguida, avaliou-se também o ganho que cada um desses modelos traz para cada UHE. Por ganho, entende-se quando um modelo obtém uma melhoria na métrica vista em relação ao modelo base (PAR), dessa forma é analisado, para cada métrica, o modelo que consegue retornar a métrica da melhor maneira possível. Por último, foi avaliado o ganho que cada preditor climático (U1, SST2 e Nino3) tem para cada hidroelétrica – inclusive com a sua espacialização. Novamente, esse ganho tem uma característica binária de ou ser melhor ou pior que o modelo base sem informação climática (PAR).

6.3.1 Avaliação dos modelos por mês e horizonte de previsão (*lead*)

Por ser de difícil representação essa quantidade de informações (157 UHEs, 12 meses, 6 horizontes de previsão e 11 anos de validação, totalizando 11.304 resultados individuais) em apenas uma imagem, esses dados são apresentados de 3 formas distintas. Primeiramente agregando todas as informações para os meses existentes e calculando o NSE, KGE e suas componentes para cada mês, juntando, portanto, diferentes horizontes de previsão para o cálculo (Figura 6.6). Outra forma é agregar pelos *leads*, juntando todos os meses de cada

reservatório para calcular as mesmas métricas (Figura 6.7). A última forma é deixando ambos isolados nos cálculos (meses e *leads*), com a representação dessa informação sendo um *heatmap*, similar a uma imagem 3D vista de cima (Figura 6.8 para o NSE e Figura 6.9 para o KGE).

Importante entender o conceito da Figura 6.6 a seguir. Nela estão 6 métricas de avaliação diferentes. Para cada uma delas o eixo-x representa os 12 meses do ano enquanto o eixo-y a quantidade de UHEs em que cada modelo foi o melhor nessa métrica específica. Por exemplo, observa-se que ao analisar a métrica NSE para o mês de janeiro, em 87 reservatórios o modelo PAR (sem informação climática) foi o melhor, em 32 UHEs o melhor modelo foi o PARX e 38 hidroelétricas obtiveram o melhor valor de NSE quando usando o modelo RIDGE. É importante entender que essa figura mostra apenas qual modelo é o melhor, sem fazer uma distinção de quão melhor um modelo foi em relação aos outros. Além disso, um modelo ter sido o melhor também não implica em um modelo “bom” – isso significa que em alguns casos, ainda se tem, por exemplo, valores de NSE negativos (inaceitáveis pela literatura).

Dessa forma, nota-se pela Figura 6.6 que há um ganho em utilizar informações climáticas nas previsões, havendo uma pequena diferença entre os modelos RIDGE e PARX quando utilizando o NSE ou o KGE. Esse ganho, pelo o NSE, varia entre 34% e 68% das UHEs quando agregados pelos meses. Já pelo KGE, o ganho varia entre 34% e 79% das usinas hidroelétricas (mostrando um aumento em comparação com a outra métrica). Nota-se também uma diferença entre os modelos mais indicados pelo NSE ou KGE, com o RIDGE sendo favorecido pela métrica NSE e o PARX pela métrica KGE.

A partir da análise individual de cada componente, percebe-se que há um ganho significativo em utilizar as variáveis climáticas para cálculo do α , por exemplo, melhorando-o em 90% e 87% das UHEs nos meses de, respectivamente, janeiro e setembro. No mínimo, a inclusão de informações climáticas nas previsões melhorou essa componente em 44% dos casos, ao considerar todos os meses juntos. Isso mostra que a inclusão de tais variáveis auxilia em uma melhor descrição da variabilidade das vazões – pois uma melhora em α representa uma variância simulada mais próxima da observada. No α há também uma clara sazonalidade que pode ser percebida. Isso quando agregando todos os horizontes de previsão, esperando então um possível ganho mais significativo para *leads* específicos.

Para a componente de correlação linear (r), há também um ganho relativamente importante na utilização de variáveis climáticas, atingindo até 71% das UHEs em mês específico (março). Vale notar que os meses com maiores ganhos na correlação se diferem dos meses da componente α , por exemplo, mostrando que o impacto da utilização de tais variáveis é diferente para cada componente. Com janeiro sendo um exemplo em que o modelo *ridge* consegue ser melhor em quase todas as UHEs para a componente α , mas estando entre um dos piores meses para a componente r .

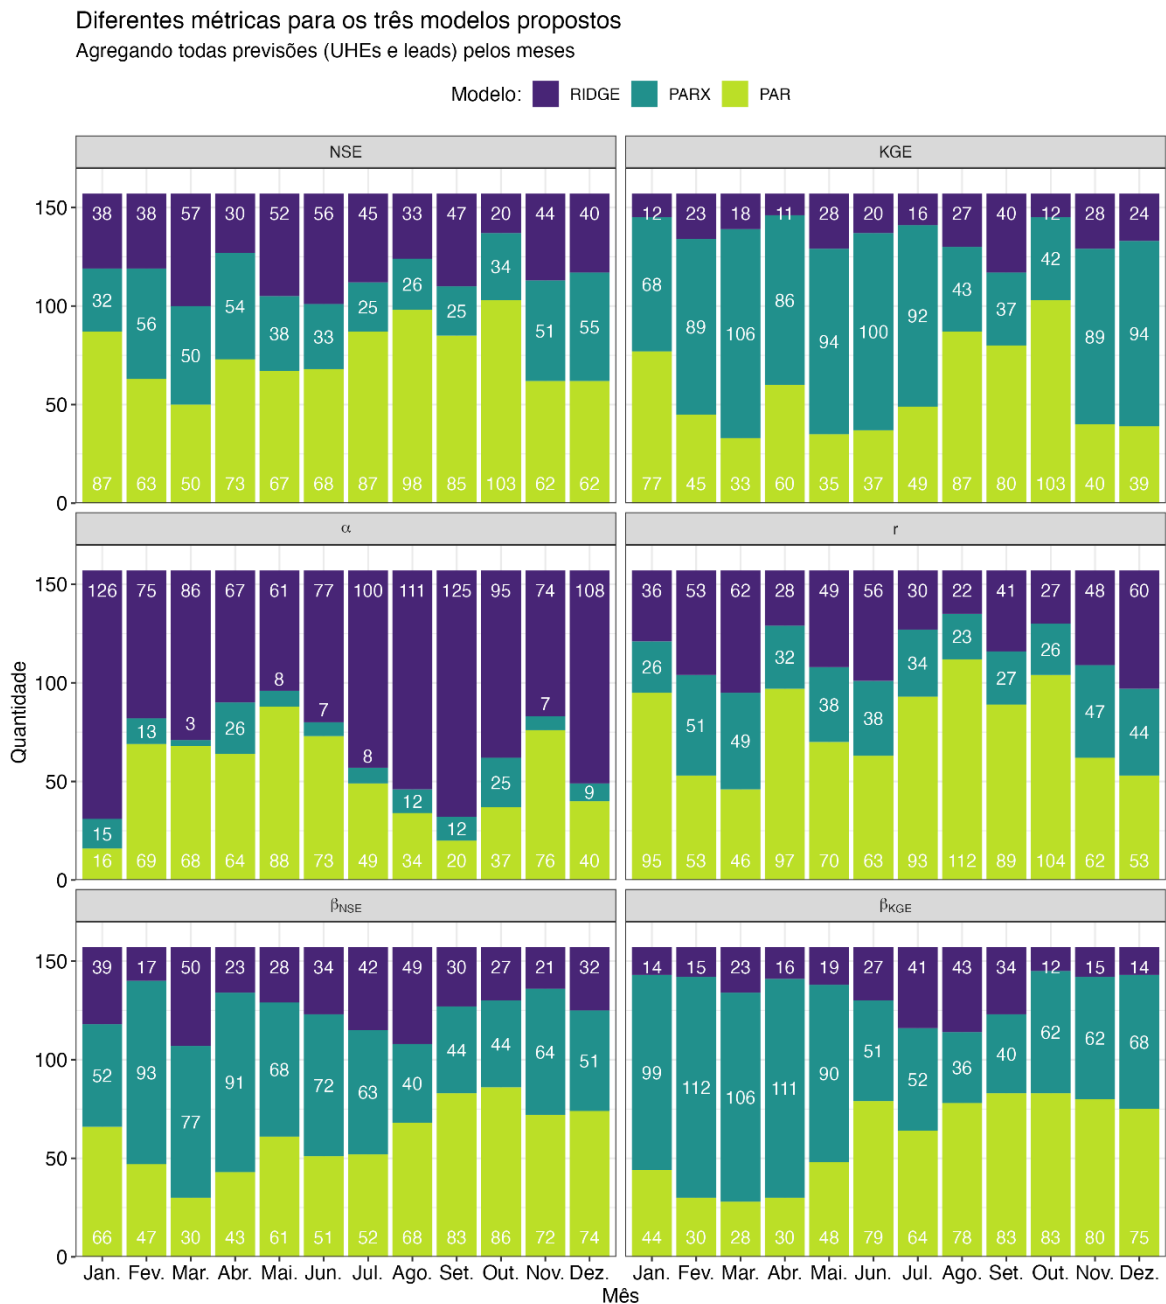


Figura 6.6 Ganho de cada modelo para diferentes meses por UHE

Por último, ainda na Figura 6.6, foram avaliadas as componentes betas (β_{NSE} e β_{KGE}), com as duas apresentando comportamentos similares entre si, tanto sazonalmente quanto na quantidade absoluta na contagem de vitórias de cada modelo. Existe uma certa sazonalidade, na qual os modelos climáticos conseguem melhorar essa componente mais vezes no primeiro semestre (época de cheias para boa parte das hidroelétricas), sendo menos efetivos no segundo (época de seca para a maioria das usinas avaliadas).

Um dos pontos mais importantes dessa avaliação é o significado desses gráficos. Avalia-se o ganho qualitativo em se utilizar variáveis climáticas nas previsões feitas por modelos estocásticos, simulando um modelo do próprio ONS (PREVIVAZM) pelo PAR. No próprio modelo do ONS, como detalhado na revisão de literatura, há uma escolha dentre possíveis modelos, sendo comparados diferentes tipos e sendo utilizado o melhor dentre eles. Dessa forma, há um ganho para o sistema mesmo que a adição de variáveis climáticas melhore apenas poucas previsões – o que não é o caso, visto que existe um ganho significativo no NSE e KGE de todos os meses.

A Figura 6.7 a seguir traz as mesmas métricas para os 3 modelos avaliados. Porém, para o cálculo dessas métricas, foram agregadas as observações e simulações de todos os meses para um mesmo horizonte de previsão. Dessa forma, busca-se avaliar o *lead time* em que ocorre um ganho no uso das variáveis climáticas.

Em um primeiro momento algo inesperado acontece quando observando os valores de NSE. Ao invés da quantidade de modelos climáticos “vitoriosos” diminuir constantemente com o *lead time*, há um comportamento variável, aumentando, diminuindo ou se mantendo com o tempo. Isso ocorre, possivelmente, porque o *lag* utilizado pela variável está “preso” no mesmo *lead* usado na previsão. Dessa forma, para prever vazões 2 períodos (meses) a frente, são utilizadas (no modelo dessa dissertação) as variáveis climáticas de 2 períodos anteriores, mesmo que exista um sinal melhor entre vazão e determinado indicador climático para tempos mais longos (3 ou 4 períodos anteriores por exemplo).

Outro fator impactante na Figura 6.7 não presente na anterior, quando se agregaram os meses, é a diferença entre o NSE e KGE. Para todos os *lead times* avaliados, há um número maior de modelos climáticos “vencedores” pelo KGE do que pelo NSE. Isso pode estar

ocorrendo devido a problemas no equacionamento do NSE em que valores de α (alpha) são preferíveis quando próximos a r ao invés de otimizados para seu valor ótimo teórico ($\alpha = 1$). Além disso, existe o comportamento esperado entre os horizontes de previsão 1 e 3 (com menos modelos climáticos ganhando do PAR à medida que esse horizonte aumenta). Esse comportamento, porém, se inverte no mês 4, possivelmente pelo mesmo problema comentado anteriormente (*lag* dos índices climáticos preso ao mesmo *lead time*).




Figura 6.7 Ganho de cada modelo para diferentes *leads* por UHE

Vale ressaltar que isso não implica que o valor do NSE ou do KGE está aumentando com o *lead time*, apenas que há mais modelos com variáveis climáticas (PARX ou *ridge*) com um NSE (KGE) maior do que o NSE (KGE) do modelo PAR. De maneira comparativa, há um ganho em se utilizar informações climáticas (pelo KGE) em 59% das UHEs para previsões um mês a frente, variando entre 50% e 57% para outros horizontes de previsão. Esses valores são mais constantes do que quando agregando os valores pelo mês, indicando uma maior sensibilidade do modelo a sazonalidade da série do que pelo *lead time* utilizado.

A análise das outras componentes revela que os modelos climáticos são capazes de melhorar a correlação linear, r , entre um número expressivo de UHEs (em 54% no primeiro *lead* e depois variando entre 45% e 56% para os outros meses). Assim, mostra-se que o uso dos três indicadores climáticos selecionados oferece um ganho na previsão das vazões futuras pelas previsões terem melhores correlações lineares com as vazões observadas.

Ademais, a componente α também tem melhoras em grande parte dos resultados, melhorando entre 54% e 62% das UHEs avaliadas nos diferentes *lead times* simulados. Para as componentes β_{NSE} e β_{KGE} , há ganho em entre 52% e 68% das hidroelétricas analisadas. Os resultados indicam que a inclusão de preditores climáticos no modelo estocástico proposto consegue aperfeiçoar as médias, variâncias e correlações das séries simuladas. É importante notar que o grau do ganho para diferentes horizontes de previsão foi calculado unindo todos os meses e, como visto pela Figura 6.6, pode ser maior ou menor a depender do mês simulado – inclusive se mostrando mais sensível ao mês do que pelo *lead*.

Agregando as previsões agora pelos meses e pelo horizonte de previsão se tem a Figura 6.8 (para o NSE) e a Figura 6.9 (para o KGE). A coloração nessas figuras é referente a quantidade relativa de UHEs que possuem um ganho em utilizar variáveis climáticas, em porcentagem. As colorações azuis representam os valores que se encontram acima de 0%, com tons escuros significando uma aproximação de 100% enquanto a cor branca significa que não há ganho nos modelos climáticos para nenhuma das hidroelétricas (não é o caso). Tons azuis mais claros não significam, portanto, uma situação ruim, apenas que o ganho da utilização de informação climática é menos frequente nas UHEs avaliadas.

Essas imagens (*heatmaps*) são a vista de cima de um plano em R^3 dos dados comentados (um eixo sendo o mês avaliado, outro eixo contendo o horizonte de previsão e por último o

terceiro eixo sendo a quantidade de UHEs com ganho ao utilizar informações climáticas). Essas imagens com o plano em 3D criado e rotacionado em 16 formas diferentes estão no APÊNDICE C – PLANO 3D DO GANHO CLIMÁTICO DOS MODELOS. A Figura 6.8 e a Figura 6.9 são um formato mais organizado na superfície “K” das figuras desse apêndice.

As figuras mostram alguns comportamentos que não são possíveis de serem observados ao agregar mensalmente ou pelos diferentes horizontes. Um diferencial sendo a possibilidade de ver nitidamente que existem pontos focais em que os modelos climáticos ganham menos ou mais vezes – algo não tão simples de notar com os agrupamentos feitos anteriormente.

Outra avaliação interessante é em relação aos meses de janeiro, abril e junho nas previsões 1 mês a frente. Nota-se que alguns ganhos em utilizar informações sobre o clima são mais efetivos em previsões mais longas. Isso aponta para o que foi comentado anteriormente, que existe a possibilidade de que para esses meses específicos, as variáveis climáticas selecionadas possuem um maior sinal para tempos anteriores. Assim, utilizar elas com um *lag* maior pode, possivelmente, trazer ganhos melhores.

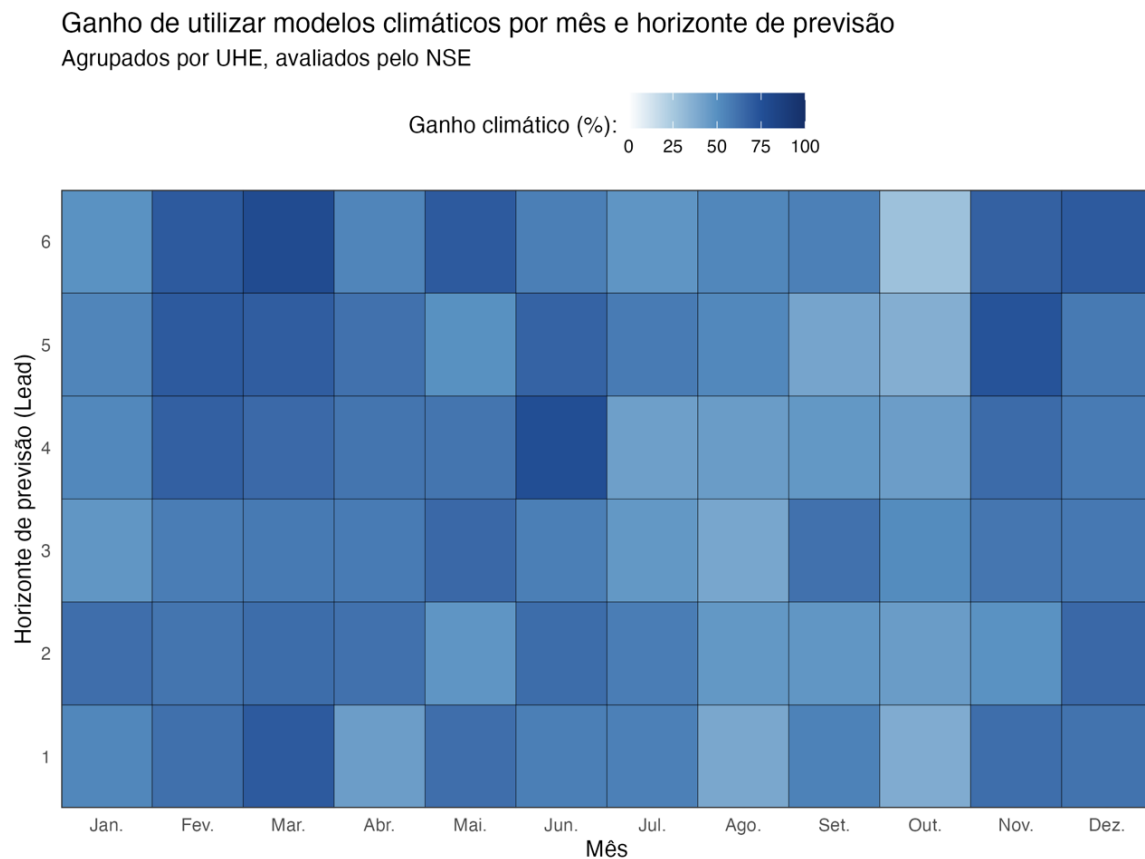


Figura 6.8 Valor do NSE para cada mês e horizonte de previsão (*lead*) por UHE

Ganho de utilizar modelos climáticos por mês e horizonte de previsão
Agrupados por UHE, avaliados pelo KGE

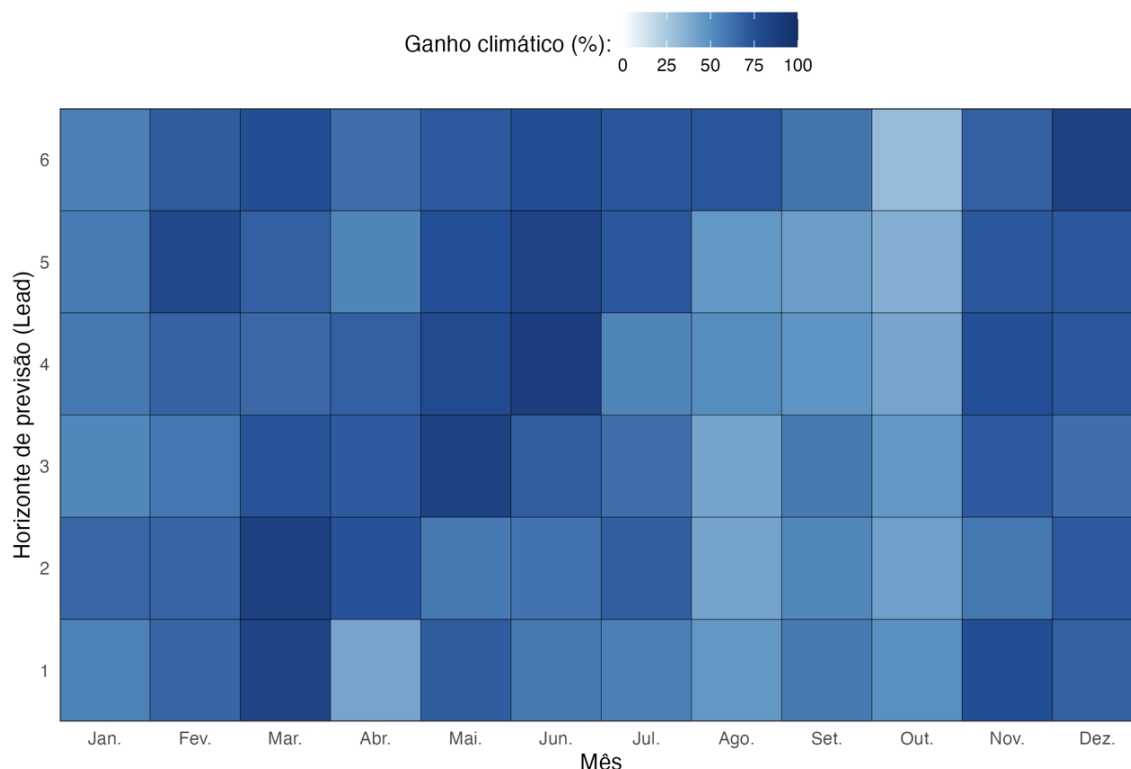


Figura 6.9 Valor do KGE para cada mês e horizonte de previsão (*lead*) por UHE

A Figura 6.9 traz algo semelhante a anterior, porém com os valores de KGE. As mesmas relações e informações são notadas aqui. A principal diferença está no tom da coloração azul, que apresenta tons mais escuros – o que significa que o ganho utilizando o KGE é mais frequente do que o ganho pelo NSE. Isso ressalta a importância de definir qual métrica é a ideal para ser avaliada, pois essa escolha também vai firmar qual o melhor modelo e qual o ganho existente em utilizar os indicadores climáticos. Esse escurecimento das cores não é uniforme, com a métrica KGE conseguindo tornar a Figura 6.9 um pouco mais fácil de ser interpretável também.

6.3.2 Análise espacial dos ganhos dos modelos climáticos

As Figura 6.10 e 6.11 mostram o ganho especializado em utilizar os preditores climáticos a partir da métrica KGE. Também foram feitos os mesmos mapas avaliando o NSE, mas não foram trazidos aqui em uma tentativa de evitar repetições por apresentarem grandes semelhanças ao KGE.

Esse ganho foi medido pela quantidade percentual de cenários em que o KGE do modelo climático (PARX ou RIDGE) foi maior do que o KGE do modelo PAR e isso é demonstrado no mapa pela transparência de cada UHE. As representações mais transparentes indicam poucos cenários com ganhos nos modelos climáticos. A coloração é apenas um indicativo do subsistema pertencente (Figura 6.10) ou do REE a qual pertence (Figura 6.11).

É importante notar que valores transparentes não indicam uma qualidade ruim do modelo. Um ganho em 10% dos cenários, ainda é um ganho positivo. Nenhuma das UHEs avaliadas obteve um ganho climático de 0%, ou seja, nas simulações feitas, sempre houve pelo menos um cenário (combinação de mês e horizonte de previsão) no qual o valor do KGE foi melhor utilizando algum dos modelos climáticos propostos (PARX ou RIDGE) do que usando apenas o modelo autorregressivo (PAR).

Na Figura 6.10 já é possível perceber um comportamento geral interessante. Os subsistemas Norte e Sul possuem os principais ganhos. O subsistema Sudeste/Centro-Oeste (SE), por outro lado, possui uma diversidade maior desse ganho climático, possivelmente pelo fato de que esse subsistema está espacialmente distribuído em um lugar maior e com um grande número de hidroelétricas individuais. Nota-se nesse subsistema (Sudeste/Centro-Oeste), porém, que nele há um ganho menor em UHEs que estão na região mais central do Brasil, existindo hidroelétricas com ganhos melhores presentes mais ao sul e mais próximos a região litorânea do País também. A região Nordeste apresenta um comportamento geral médio, não tendo usinas com ganhos tão bons quanto o Norte e o Sul, mas sendo melhores do que aquelas que se encontram nas áreas mais centrais do Brasil.

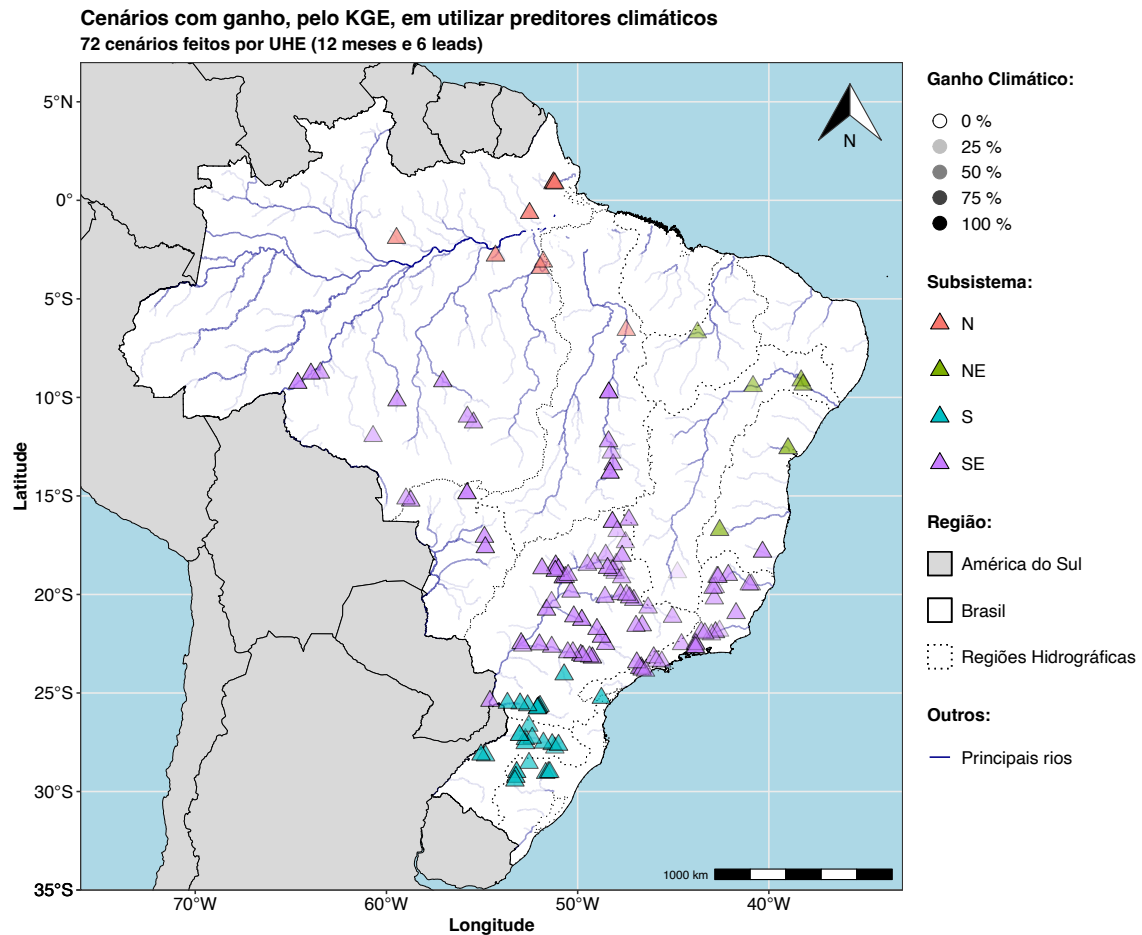


Figura 6.10 Ganho climático (transparência) das UHEs agrupadas por subsistema

Com a Figura 6.11 nota-se um maior detalhamento dessa subdivisão, por estarem agregados por REE e não subsistema. No Norte, por exemplo, observa-se que o REE Amazonas é de fato melhor do que a de Belo Monte e do REE Norte também. Uma grande diferença em relação a figura anterior é sobre o subsistema Sudeste/Centro-Oeste, pois aqui temos um maior refinamento dessa área. Nota-se que, de fato, as áreas mais centrais, compostas pelos REEs Madeira, Teles Pires e algumas do Sudeste não apresentam um ganho muito alto.

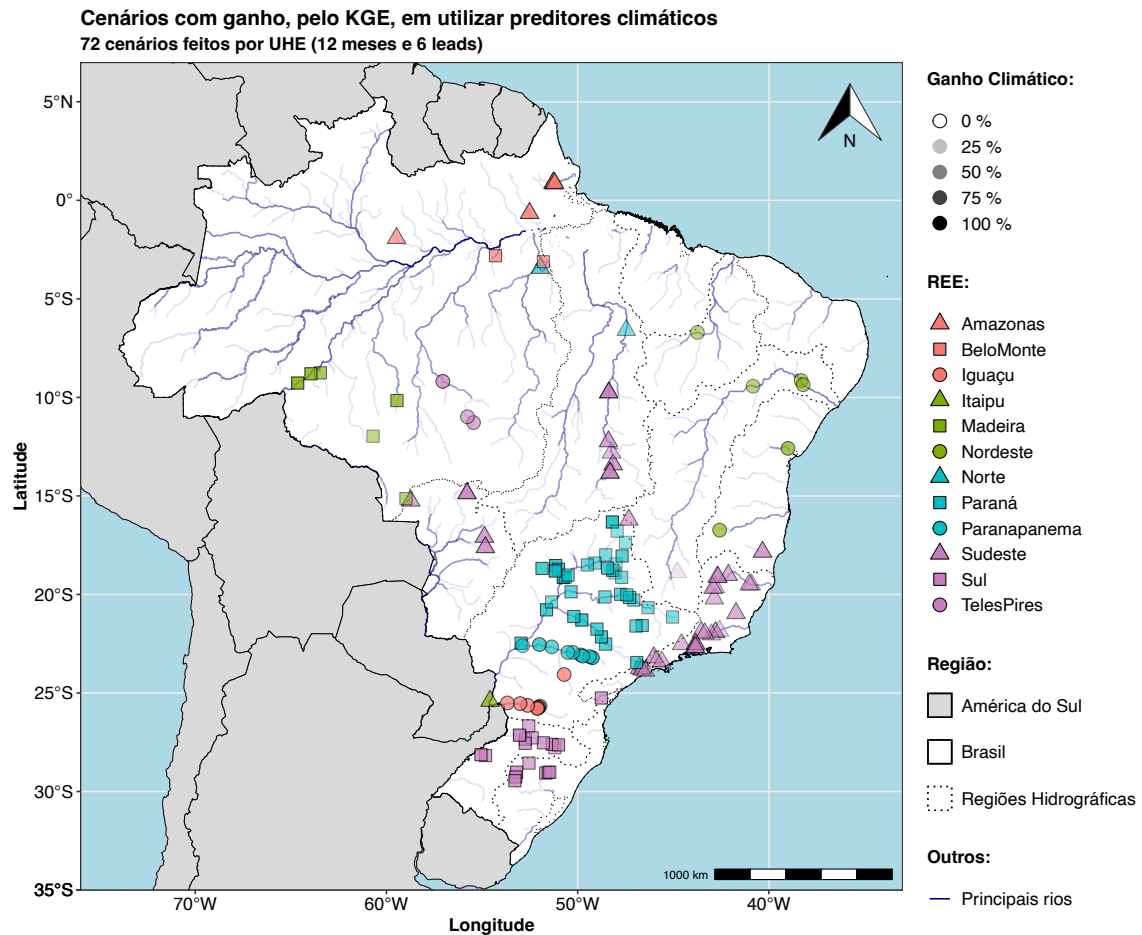


Figura 6.11 Ganho climático (transparência) das UHEs agrupadas por REE

6.3.3 Ganho quantitativo dos modelos

As avaliações mostradas até aqui são a respeito da existência (ou falta) de ganho em utilizar informações climáticas para auxiliar previsões de vazões nas hidroelétricas do SIN, despachadas pelo ONS. Porém não trazem informações sobre o valor numérico do ganho ao utilizar esses indicadores. Em um primeiro momento o importante realmente é saber se existe um ganho, mas é igualmente relevante para o presente estudo conseguir quantificar ele.

Isso é mostrado pela Figura 6.12 com gráficos de densidade e diagramas de caixa para os valores do NSE, KGE, α , r , β_{NSE} e β_{KGE} apenas em casos em que há ganho ao utilizar preditores climáticos. Os limites no eixo-x estão ajustados para mostrar os principais pontos, não sendo mostrado a totalidade das medições em alguns casos como do NSE e KGE por terem situações em que seus valores destoam muito dos outros. Nas situações em que alguns

valores são cortados da imagem, é simbolizado um asterisco vermelho (*) nos limites correspondentes. A linha vermelha tracejada mostra o valor ótimo de cada componente.

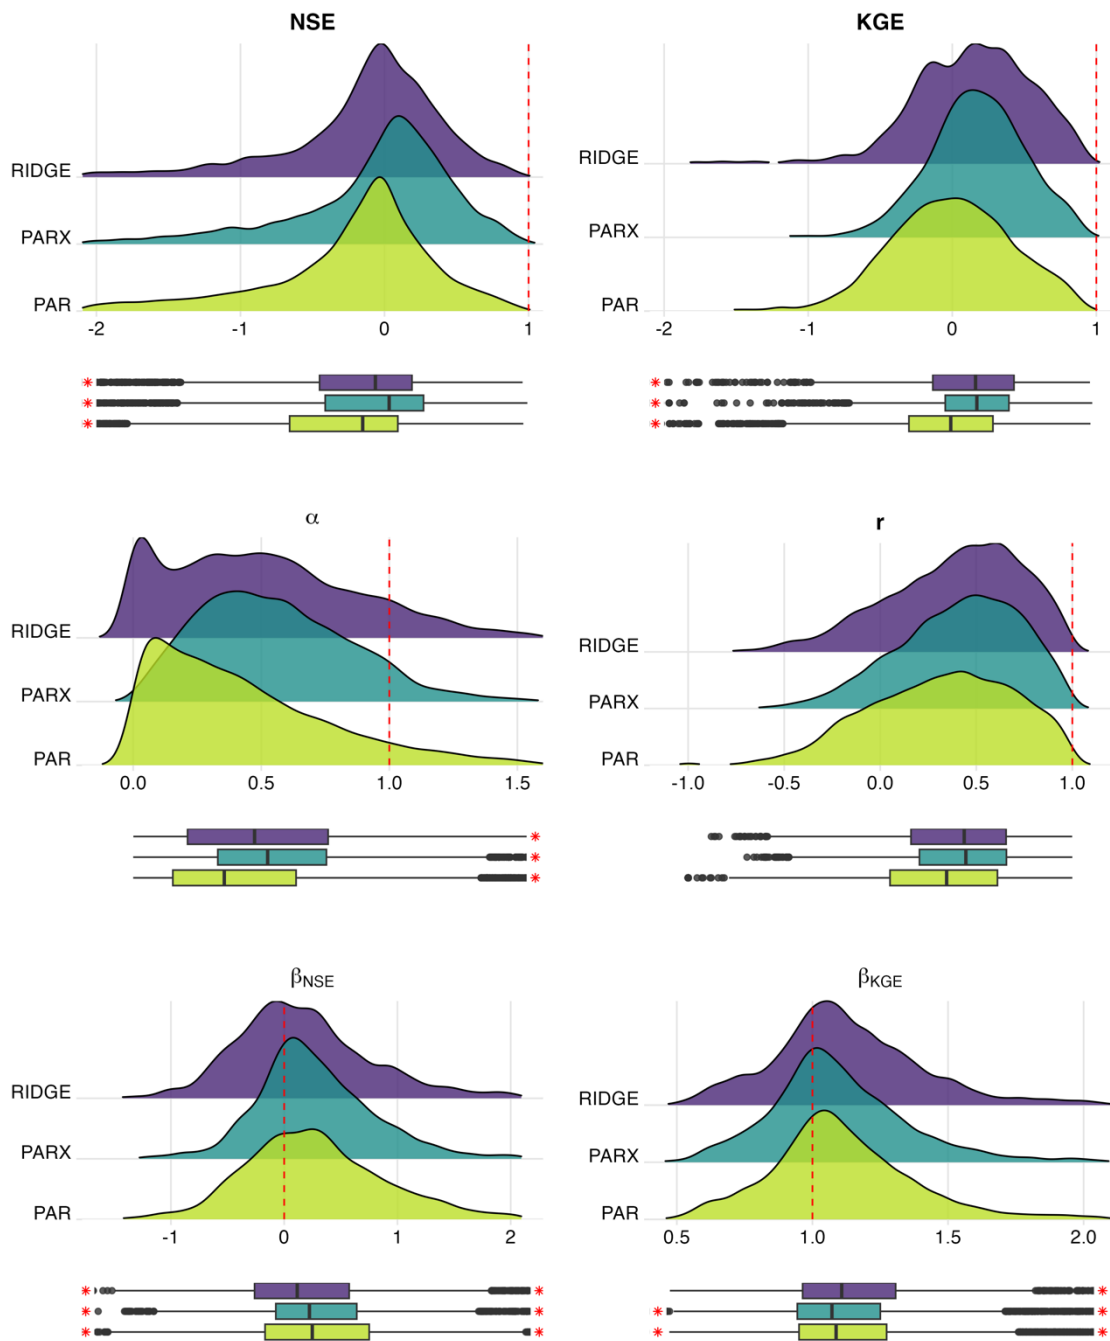


Figura 6.12 Valor das componentes avaliadas para os diferentes modelos usados

Com essa figura (Figura 6.12) é possível observar a variação no comportamento geral de cada componente. É interessante perceber que a densidade do modelo PAR utilizado (para o NSE e KGE) apresenta valores positivos e negativos, mostrando que há ganho climático para diversos valores dessas métricas, não apenas quando o modelo PAR está com valores baixos.

Ainda em relação ao NSE e KGE, nota-se uma tendência maior de se obter valores mais próximos a 1 com o uso dos preditores climáticos (com os modelos RIDGE e PARX). O modelo PARX se mostra como tendo, na média, valores melhores, porém com uma cauda mais acentuada ao se aproximar do 1, especialmente avaliando o KGE.

Para as outras componentes, verifica-se que os valores de α são significativamente melhorados, mas ainda se encontram relativamente distantes de seu ponto ótimo ($\alpha = 1$), o que dá um entendimento que é possível uma melhora maior nesse ponto, para modelos futuros. O modelo PARX apresentou ser a melhor opção nesse indicador, apesar do RIDGE também se mostrar acima do PAR. A correlação também foi melhorada de forma bem clara, com ambos modelos mostrarem ganhos similares entre si (RIDGE e PARX).

Para os valores de β , a melhora também é visível, mas existindo diferentes comportamentos para os dois valores de β . O modelo RIDGE apresenta uma média mais próxima de 0 para o β_{NSE} , com uma distribuição mais uniforme ao redor dele, mostrando uma certa constância. Para a componente β_{KGE} , porém, o modelo PARX se torna o mais adequado (mais próximo a 1, pois o equacionamento é outro, dado pela equação 3.28), com todos os modelos apresentando uma cauda para a direita. Essa cauda implica que a média das simulações feitas são maiores do que a média da série histórica.

A Figura 6.13 na sequência traz a mesma ideia da Figura 6.12, porém mostrando o ganho numérico de se utilizar esses modelos climáticos. Assim, a densidade mostrada para cada métrica e suas componentes é referente ao ganho em cima do modelo autorregressivo PAR.

Importante lembrar que para essas figuras (6.12 e 6.13) estamos apenas avaliando os cenários que apresentaram ganho na utilização de informação climática, de tal forma as métricas NSE e KGE sempre possuem um ganho positivo. Porém, não necessariamente as componentes irão seguir esse comportamento. Os asteriscos vermelhos (*) nos diagramas de caixa abaixo das densidades simbolizam que existem pontos nessa direção fora dos limites mostrado pela densidade.

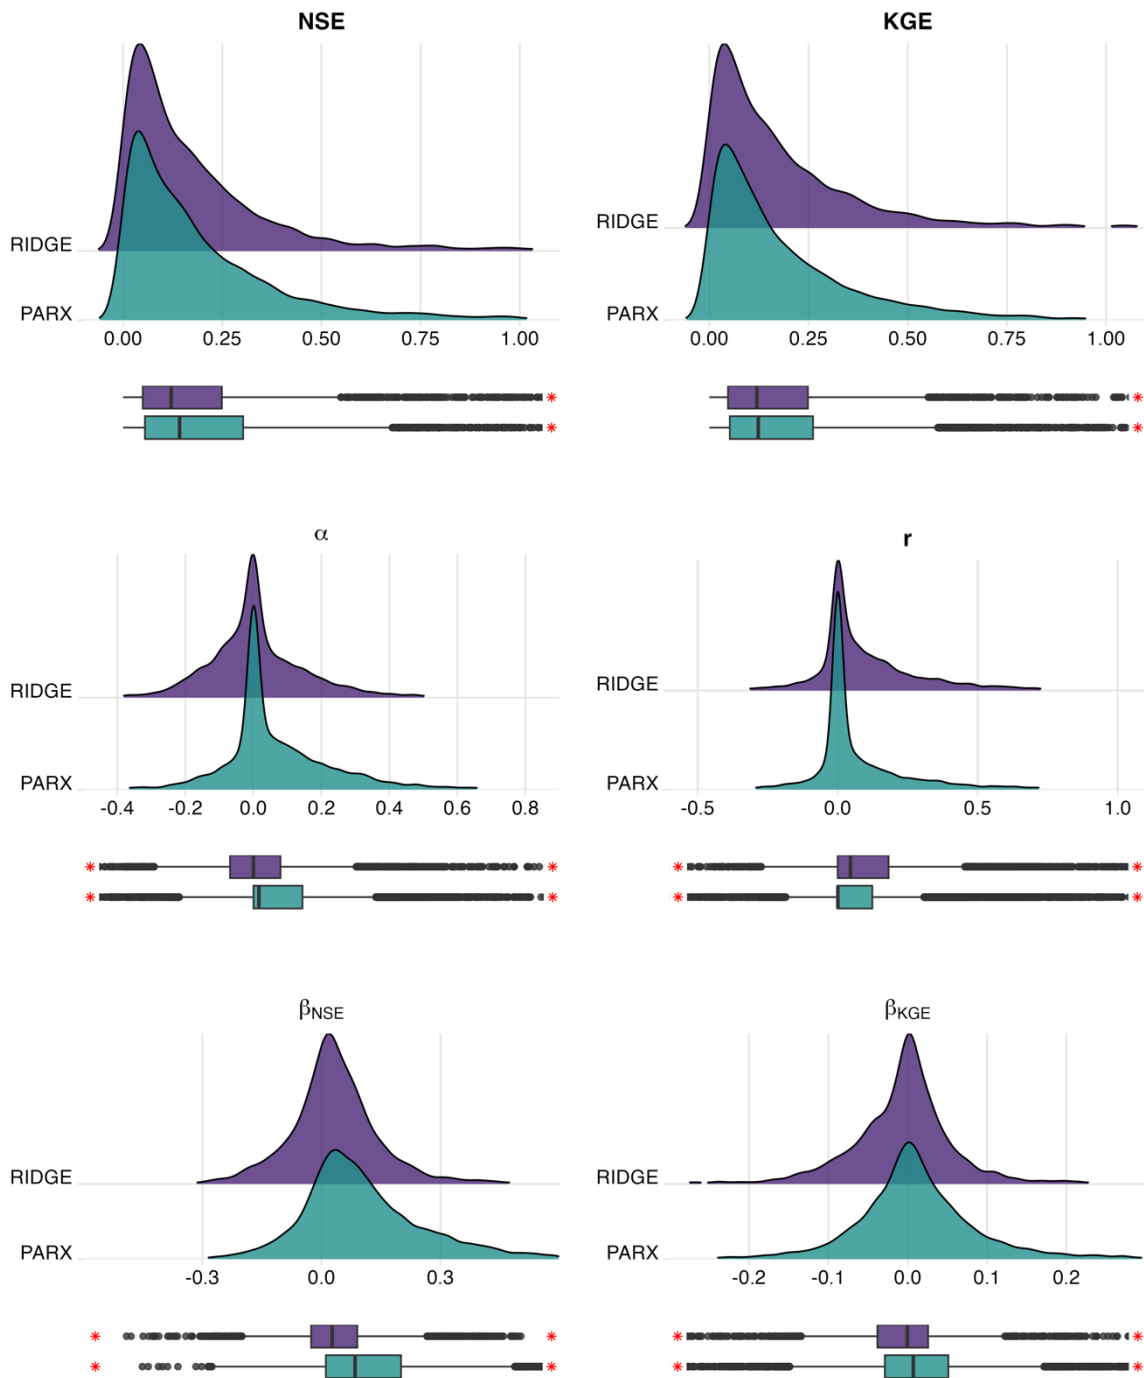


Figura 6.13 Ganho das componentes avaliadas com os modelos climáticos

A respeito do ganho desses modelos climáticos (Figura 6.13), nota-se alguns pontos relevantes. Primeiramente as métricas NSE e KGE possuem um ganho interessante, apesar de não conseguirmos quantificar a significância ou impacto desse ganho. Para o modelo PARX e pelo NSE, a média e mediana são de, respectivamente 0,982 e 0,142 (

Tabela 6.1) – mostrando que existem valores extremamente altos, o que leva a média para números não tão representativos. Há ganhos muito altos nessa métrica (NSE), assim como no KGE, pois existem modelos do tipo PAR muito ruins (tendo valores da ordem de -100). Assim, é possível um ganho numérico grande sem necessariamente deixar o modelo “bom” (uma melhora no NSE de um modelo de -100 para -1 ainda representa um modelo “ruim” no final).

De tal forma, optou-se por comparar as medianas (quando a média e mediana são claramente distintas). Assim, o modelo PARX possui um ganho mediano de 0,142 (NSE) e 0,123 (KGE) enquanto o modelo RIDGE possui ganho de 0,121 (NSE) e 0,120 (KGE). A diferença entre a média e mediana pelo KGE não é tão alta, indicando novamente motivos para se utilizar essa outra métrica.

Para as métricas do α , r e para ambas componentes β , observa-se que há casos com ganhos e pioras dos valores, sendo possível de observar pelo IQR (distância inter-quartil) do próprio diagrama de caixa abaixo das densidades plotadas na Figura 6.13 se existem mais ganhos ou perdas. Mesmo com essas pioras, é importante notar que todos os pontos são de cenários em que houve melhora pela métrica NSE ou KGE e, portanto, mesmo piorando uma componente específica, a métrica ficou melhor (significando que, portanto, os ganhos nas outras componentes foram impactantes).

Numericamente esses ganhos podem ser avaliados pela tabela 6.1 a seguir, mostrando o ganho mínimo, médio, mediano e máximo de cada modelo para cada componente avaliada. Nota-se que aqui estão apenas os modelos que apresentaram valores de NSE (ou KGE, no caso de suas componentes específicas) maiores do que o modelo PAR, de modo a avaliar o comportamento do ganho climático quando ele existe. Os números da tabela estão arredondados para a terceira casa decimal.

Existe um ganho em ambos os modelos climáticos (PARX e RIDGE). Ao avaliar o NSE e o KGE, o ganho médio chega até 0,982 – o que é substancial – porém traz pouca informação sobre o modelo em si. Como já discutido anteriormente, um problema de métricas como o NSE e KGE é que um aumento de 0,982 neles traz um significado pouco interpretável, pode-se apenas inferir que há um ganho.

Tabela 6.1 – Ganho de cada componente para os modelos climáticos

Modelo	Componente	Mínimo	Média	Mediana	Máximo
PARX	NSE	~ 0	0,982	0,142	376,452
	KGE	~ 0	0,218	0,123	44,669
	α	- 11,676	0,066	0,016	10,023
	r	- 0,978	0,081	0,001	1,364
	β_{NSE}	- 2,698	0,165	0,085	15,805
	β_{KGE}	- 1,755	0,056	0,007	52,421
RIDGE	NSE	~ 0	0,248	0,121	22,984
	KGE	~ 0	0,185	0,120	10,377
	α	- 4,832	0,017	0,000	10,023
	r	- 1,260	0,112	0,045	1,371
	β_{NSE}	- 1,287	0,035	0,027	2,084
	β_{KGE}	- 0,878	- 0,002	- 0,001	1,404

Por isso é importante a informação acerca das outras componentes. Observa-se então que para o modelo PARX o ganho climático mais significantes é na componente β_{NSE} , que possui o um ganho médio e mediano de, respectivamente, 0,165 e 0,085. Esse ganho chega a ser mais do que 12 vezes maior o ganho mediano, por exemplo, da componente β_{KGE} , de formulação similar. Importante lembrar que isso são os valores médios e medianos de um grande número de cenários (11.304), sendo importante avaliar não apenas os valores numéricos tabelados, mas os gráficos de densidade da Figura 6.13.

Apenas no contexto de cenários específicos, há ganhos extremamente expressivos quando se avalia apenas os ganhos máximos. Com o modelo PARX, o NSE consegue aumentar pouco mais de 376, o KGE consegue um aumento de sua métrica de quase 45, o α de 10, a correlação linear (r) consegue melhorar 1,3 (a melhor melhora possível seria de 2), o β_{NSE} 15,8 e o β_{KGE} consegue uma melhora de 52,4. Apesar das componentes α e r também terem uma perda (ganho negativo) também com valores notáveis, nas componentes β_{NSE} e β_{KGE} isso não ocorre.

O modelo RIDGE é capaz de ter um ganho maior (em termos de média e mediana) apenas na componente de correlação linear, r . Conseguindo uma melhora média de 40 % sobre o PARX e uma melhora mediana expressiva (de 0,001 para 0,045). Assim, os resultados apontam que o modelo RIDGE consegue simular melhor o comportamento genérico de

tendências da série observada (representado pela correlação linear), enquanto o PARX é capaz de captar as variâncias e médias das séries observadas de uma maneira mais realista.

6.3.4 Ganho de cada indicador climático

Nessa seção avalia-se a porcentagem de cenários em que há um ganho, pelo KGE, em utilizar o modelo RIDGE ou PARX quando utiliza-se apenas uma das variáveis climáticas por vez, com o U1, SST2 e NINO3 estando, respectivamente, na Figura 6.14, na Figura 6.15 e na Figura 6.16 a seguir. Esse ganho é percebido pela transparência das UHEs individuais com valores mais transparentes (se aproximando então do fundo branco) representando ganho em um menor número de cenários. Importante ressaltar que esses cenários são aqueles em que há ganho climático pela metodologia proposta, sendo em seguida avaliado o ganho individualmente por cada um dos preditores climáticos.

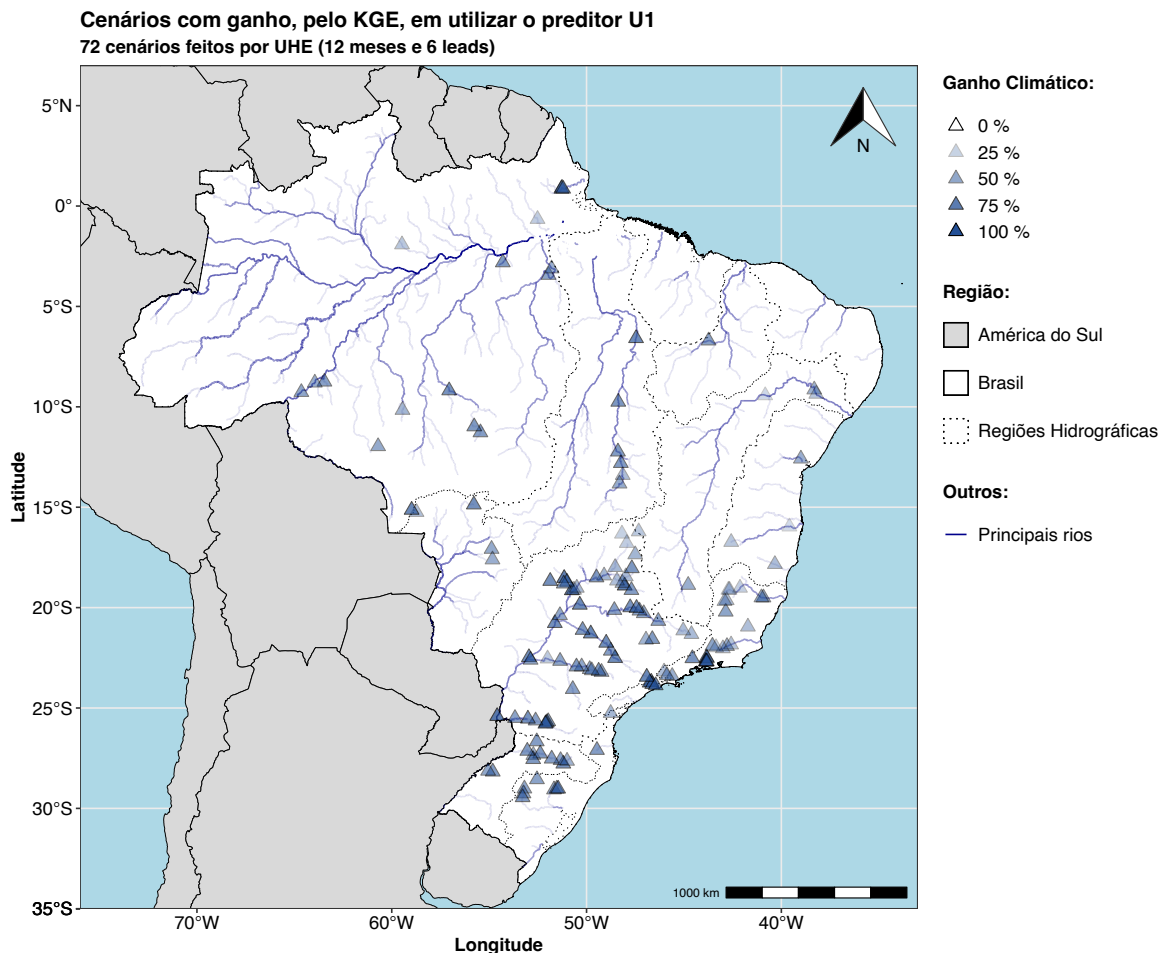


Figura 6.14 Ganho climático (transparência) do uso do preditor U1 nas previsões

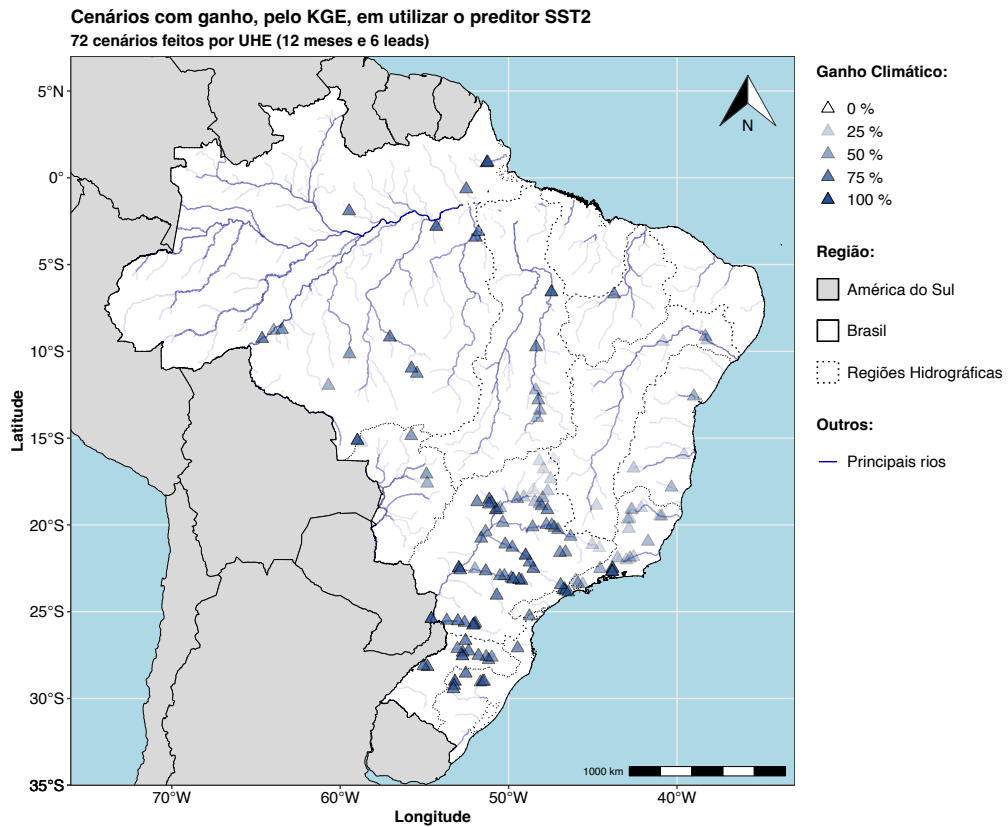


Figura 6.15 Ganho climático (transparência) do uso do preditor SST2 nas previsões

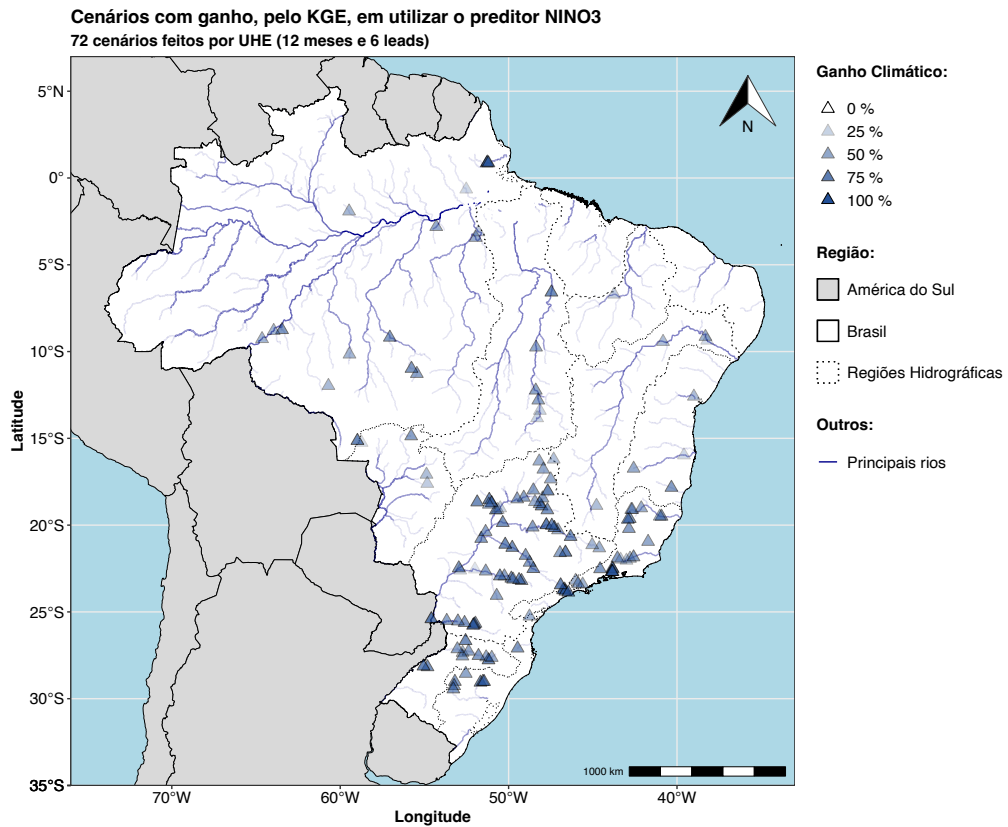


Figura 6.16 Ganho climático (transparência) do uso do preditor U1 nas previsões

De uma forma geral, as três componentes apresentam comportamentos semelhantes para as 157 UHEs. Com a maioria estando em torno de 50%, mas as hidroelétricas da região mais ao Norte do Brasil e algumas do Sul, sudeste e Centro-Oeste tendo uma coloração mais forte (ganho maior). As piores regiões (com menor ganho climático) são no Nordeste brasileiro e algumas áreas mais centrais do Brasil. Essa espacialização é mais visível nas seções seguintes, onde é feita a análise por REE ou subsistema.

6.4 REEs

As mesmas avaliações mostradas nos resultados para as hidroelétricas individuais são refeitas aqui, porém, unindo os dados dessas usinas em REEs. Ao invés de serem agregadas por mês e horizonte de previsão, nessa seção trazemos apenas o *heatmap* da Figura 6.17. Os resultados agregando as métricas pelo mês e/ou pelo horizonte de previsão (similar a Figura 6.6 e a Figura 6.7) apesar de feitos, não são trazidos aqui por não mostrarem comportamentos diferentes e a fim de evitar redundâncias. Mesmo assim, eles podem ser vistos no APÊNDICE D – RESULTADOS PELO CONCEITO DE REE no final deste trabalho.

A Figura 6.17 mostra o ganho, avaliado pelo KGE, quando agrupando as UHEs individuais em REEs. Esses valores são, portanto, representados de forma discreta (existindo apenas 5 colorações possíveis) ao invés de forma contínua (uma rampa de cores). Isso facilita a visualização de sazonalidades específicas. Claramente os meses de janeiro, agosto, setembro e outubro estão entre os piores.

Enquanto isso, os meses entre março e julho, assim como novembro e dezembro, apresentam uma notável melhoria na utilização de indicadores climáticos. Ainda é possível identificar que não existe uma perda de ganho climático sistemática com o aumento do horizonte de previsão.

Ao avaliarmos usando esse conceito de REE, é ainda mais interessante a visualização espacial do ganho climático. A Figura 6.18 traz essa informação mais clara do que quando representando cada hidroelétrica individual. Apesar do ganho ser menor (agrupamos as diferentes UHEs com diversos comportamentos hidráulicos-hidrológicos), é mais facilmente interpretável a localização dos ganhos em utilizar os preditores climáticos.

Ganho de utilizar modelos climáticos por mês e horizonte de previsão

Agrupados por REE, avaliados pelo KGE

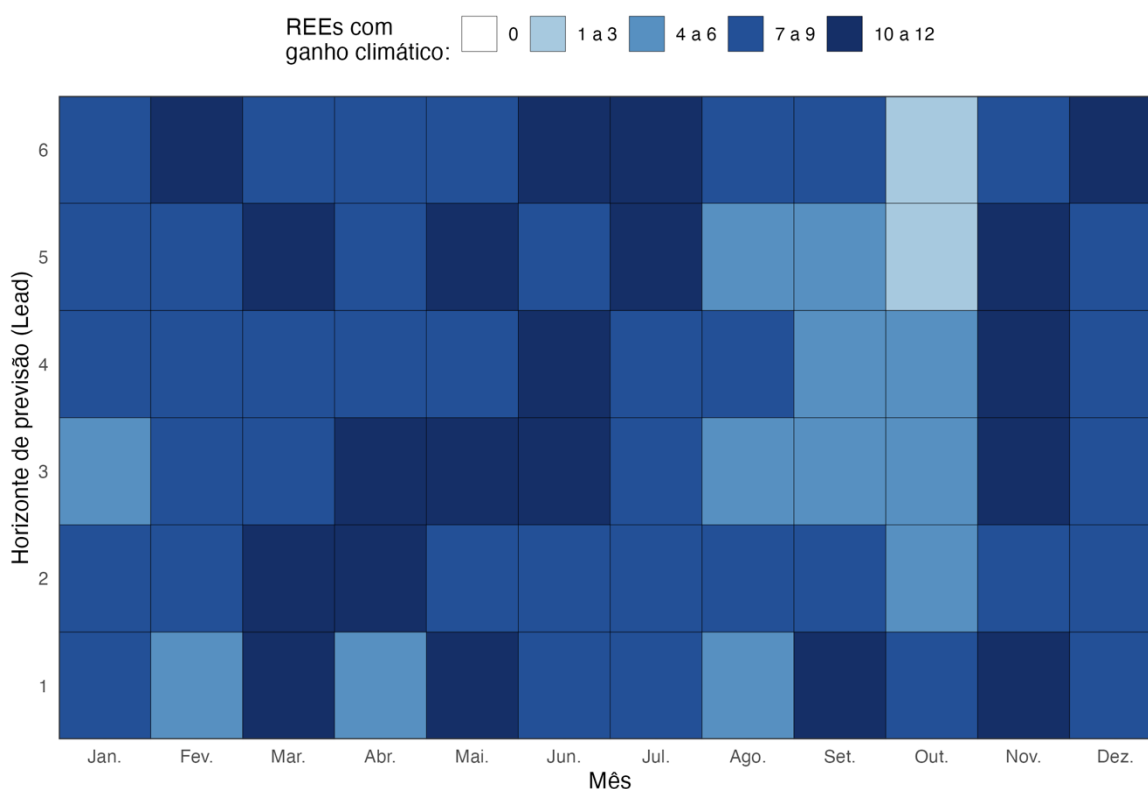


Figura 6.17 Valor do KGE para cada mês e horizonte de previsão (*lead*) por REE

São alguns REEs específicos que possuem os maiores ganhos como o de Amazonas, Belo Monte, Norte, Itaipu e Iguaçu com, respectivamente, 83%, 76%, 72%, 83% e 71%. Já os do Nordeste e de Sudeste possuem os menores ganhos (próximos a 50%). Os outros REEs possuem valores intermediários, com ganho climático entre 60% e 70% dos cenários.

Importante ressaltar novamente que esse resultado mostrado pela Figura 6.18 leva em consideração todos os meses e horizontes de previsão. Existem meses e *leads* com valores mais altos e mais baixos do que os mostrados neste mapa, mas isso informa um contexto mais generalizado, ou um panorama geral. O impacto dos índices U1, SST2 e NINO3 são maiores em regiões específicas (com os piores reservatórios equivalentes sendo o Nordeste e o Sudeste), apesar de existir ganho em todas os REEs – a Figura 6.17, por exemplo, não possui nenhuma combinação de horizonte de previsão e mês com nenhum REE tendo ganho climático (cor branca).

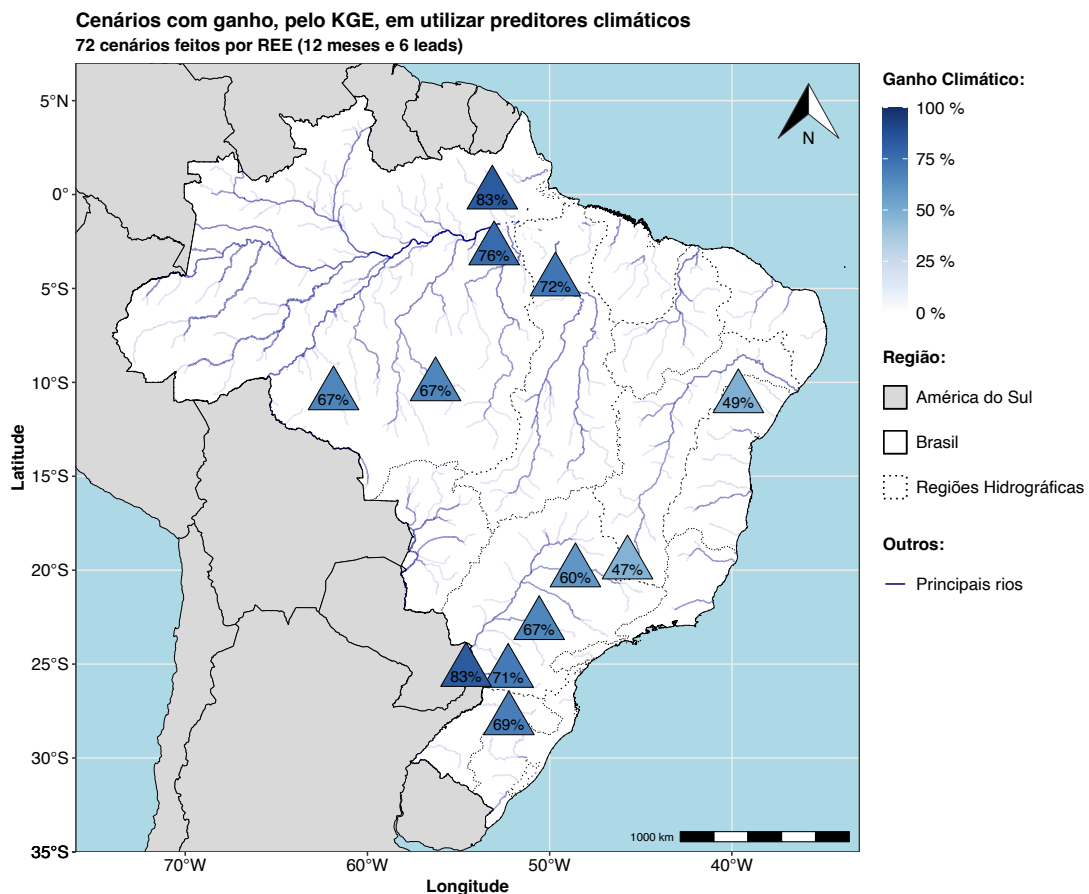


Figura 6.18 Ganho climático dos REEs pelo KGE

A seguir, é mostrado o ganho climático de utilizar cada preditor individualmente nos cenários em que há um ganho utilizando a metodologia proposta – isso é mostrado pela Figura 6.19, Figura 6.20 e Figura 6.21. Apesar de todos os três indicadores apresentarem um ganho com seu uso, algumas características podem ser percebidas.

Por exemplo, o indicador U1 possui o maior ganho climático nos REEs Iguazu, Norte, Paraná e Sudeste. Já o preditor SST2 é predominante nos reservatórios equivalentes Amazonas, Belo Monte, Itaipu, Madeiras, Paranapanema, Sul e Teles Pires – sendo, portanto, o mais predominante dos indicadores climáticos. Por último, a variável climática NINO3 possui maior ganho apenas no REEs Nordeste (esse, inclusive, tendo o segundo pior ganho, apesar de ainda em 49%).

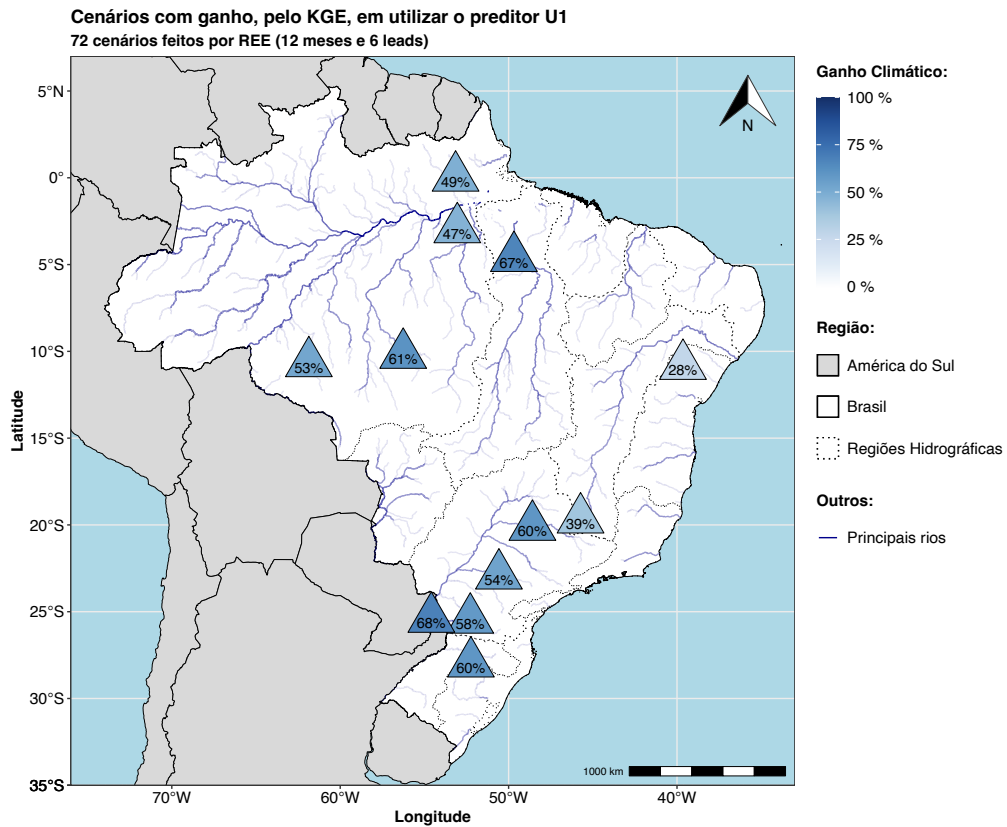


Figura 6.19 Ganho do uso do preditor U1 nas previsões por REE

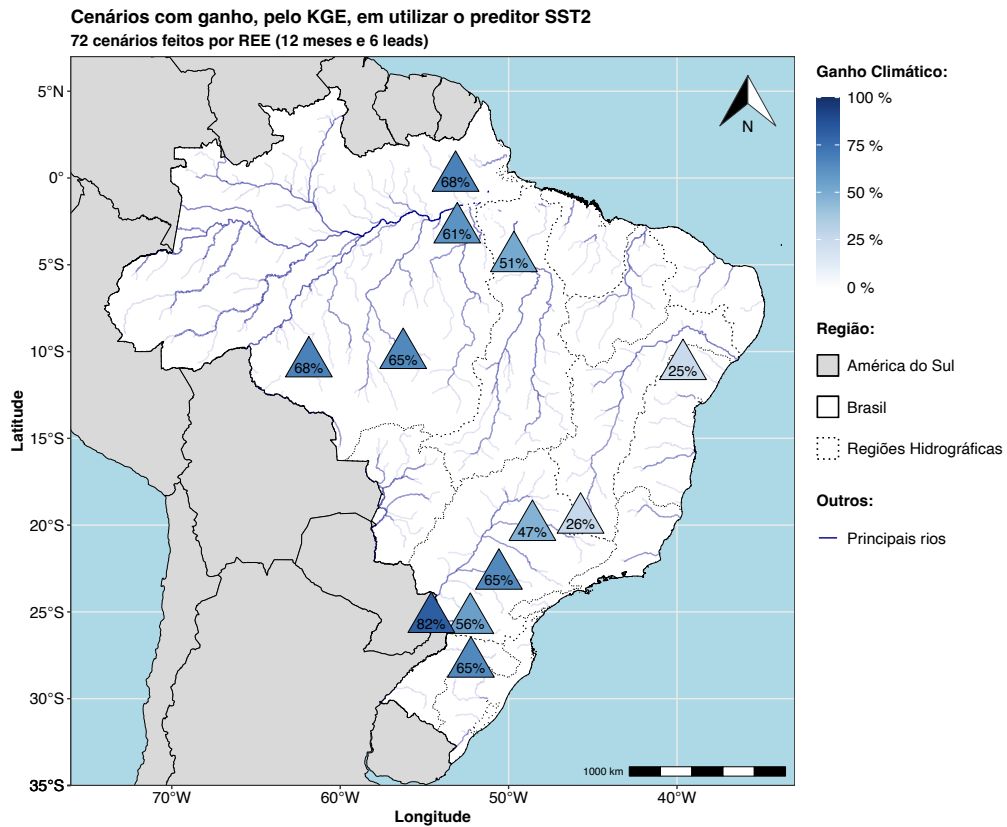


Figura 6.20 Ganho do uso do preditor SST2 nas previsões por REE

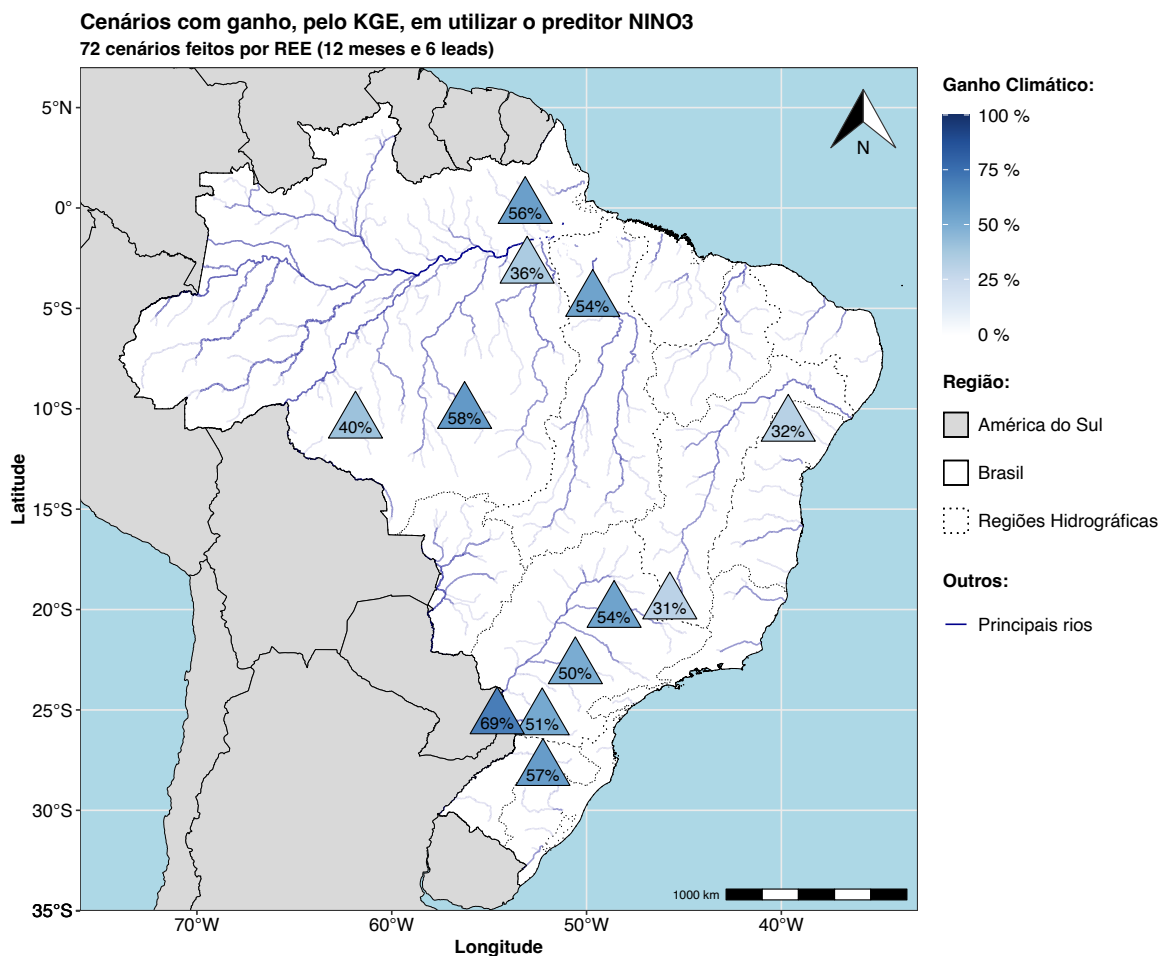


Figura 6.21 Ganho do uso do preditor NINO3 nas previsões por REE

6.5 SUBSISTEMAS

Similar ao feito usando o conceito de REE, aqui são trazidos apenas alguns dos resultados mais importantes. Todas as análises feitas para UHEs e para REEs foram replicadas a níveis dos subsistemas. Quando o comportamento não mostrou uma diferença significativa ou que considerada como relevante pelo autor, essa entrou no corpo deste texto – ainda estando disponível no APÊNDICE E – RESULTADOS PELO CONCEITO DE SUBSISTEMAS.

A Figura 6.22 e a Figura 6.23 trazem a informação acerca do número de subsistemas em que há ganho pelo NSE (Figura 6.22) e pelo KGE (Figura 6.23) para cada combinação de mês e horizonte de previsão. Por existirem apenas 4 subsistemas, aqui é possível trazer uma coloração para cada possibilidade (indo de 0 até 4), o que demonstra uma informação mais precisa do que quando avaliando os REEs ou as UHEs individuais.

Diferentemente do ocorrido anteriormente, ao agregar todas informações em subsistemas, há momentos em que não há nenhum ganho em nenhum dos modelos climáticos quando comparados ao modelo PAR. Porém esses momentos são diferentes quando avaliando o NSE ou KGE (tanto a posição quando a quantidade deles).

Avaliando apenas o NSE (Figura 6.22), a quantidade de cenários com 0, 1, 2, 3 e 4 subsistemas é de, respectivamente, 2, 23, 31, 15 e 1. Já pelo KGE (Figura 6.23), a quantidade de cenários com 0, 1, 2, 3 e 4 subsistemas é de, respectivamente, 2, 9, 22, 29 e 10. Isso reforça novamente a importância na definição de qual métrica utilizar para determinar o ganho de diferentes modelos. A métrica do KGE é, para esse caso, mais impactante para avaliar os modelos climáticos. Isso pode acontecer pelo fato de que os modelos propostos neste trabalho (PARX e RIDGE) melhoram as componentes individuais, o que nem sempre melhora a métrica do NSE, mas também pode acontecer pelo fato de que métricas diferentes vão ter resultados diversos – e ambas o NSE e KGE são métricas diferentes.




Figura 6.22 Valor do NSE para cada mês e *lead* por subsistema

Ganho de utilizar modelos climáticos por mês e horizonte de previsão
Agrupados por Subsistema, avaliados pelo KGE




Figura 6.23 Valor do KGE para cada mês e *lead* por subsistema

Similar quando avaliando os REEs, a espacialidade desse ganho climático se mostra interessante no contexto de subsistemas (Figura 6.24). O mesmo visto anteriormente é reforçado aqui. Com os subsistemas Norte e Sul sendo os com maiores ganhos climáticos (78% e 69%). O Sudeste/Centro-Oeste tendo um ganho moderado (54%) e o subsistema com menor ganho sendo o Nordeste (49%). Ainda assim, esse ganho no Nordeste existe e é de 49% – isso em relação aos 72 cenários feitos (12 meses e previsões de 1 a 6 meses a frente).

Na sequência, são trazidos três mapas (Figura 6.25, Figura 6.26 e Figura 6.27) referentes ao ganho específico de utilizar apenas um dos indicadores climáticos por vez (U1, SST2 e o NINO3). O U1 possui o melhor valor no Norte e no Sudeste/Centro-Oeste, enquanto o SST2 não é predominante em nenhum subsistema. O NINO3, portanto, ganha nas regiões Nordeste e Sul. Isso não vai de acordo com o visto quando agrupados por REE, com o SST2 (mais predominante então) não possui nenhum ganho em relação aos outros indicadores. É interessante notar que os valores não são aditivos. Existe uma relação entre esses indicadores climáticos, porém essa é uma relação não linear e extremamente complexa, dificultando a interpretação do ganho ao utilizar mais de um preditor concomitantemente.

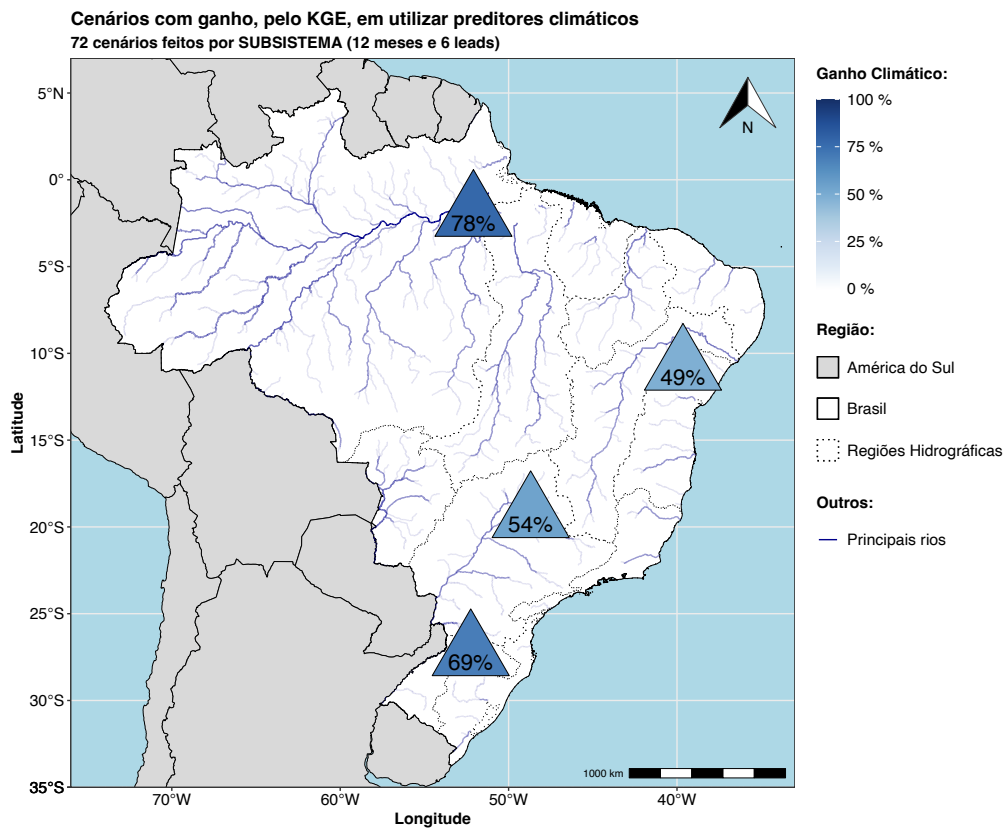


Figura 6.24 Ganho climático dos subsistemas pelo KGE

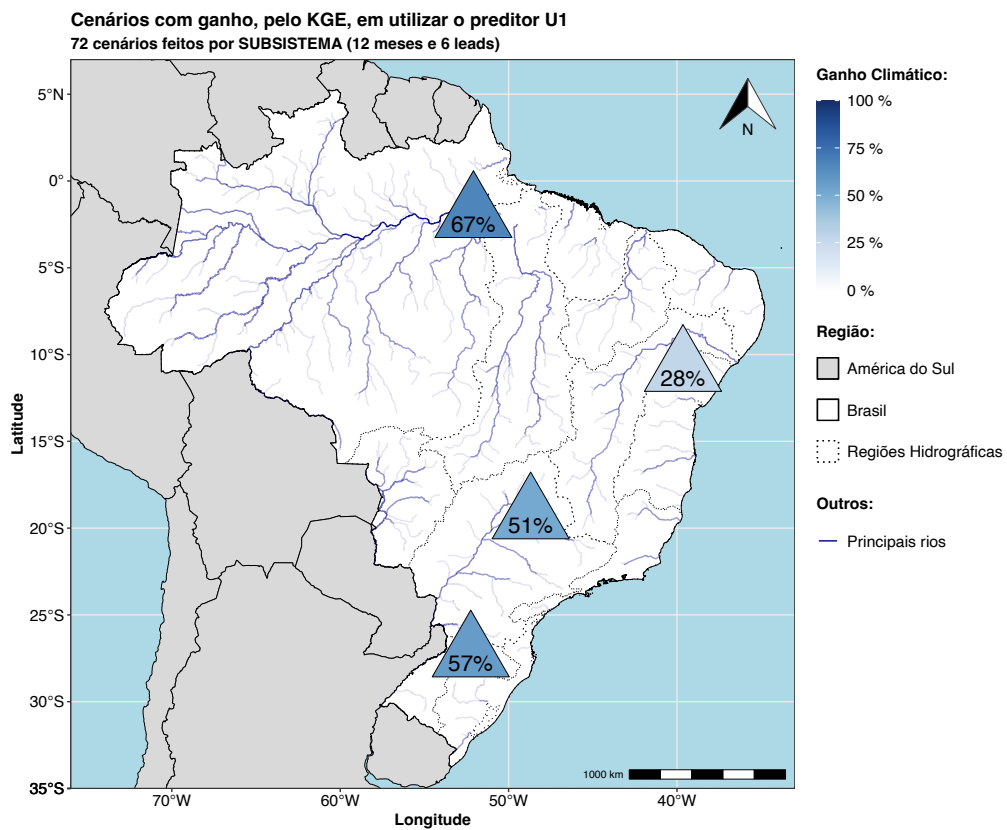


Figura 6.25 Ganho do uso do preditor U1 nas previsões por subsistemas

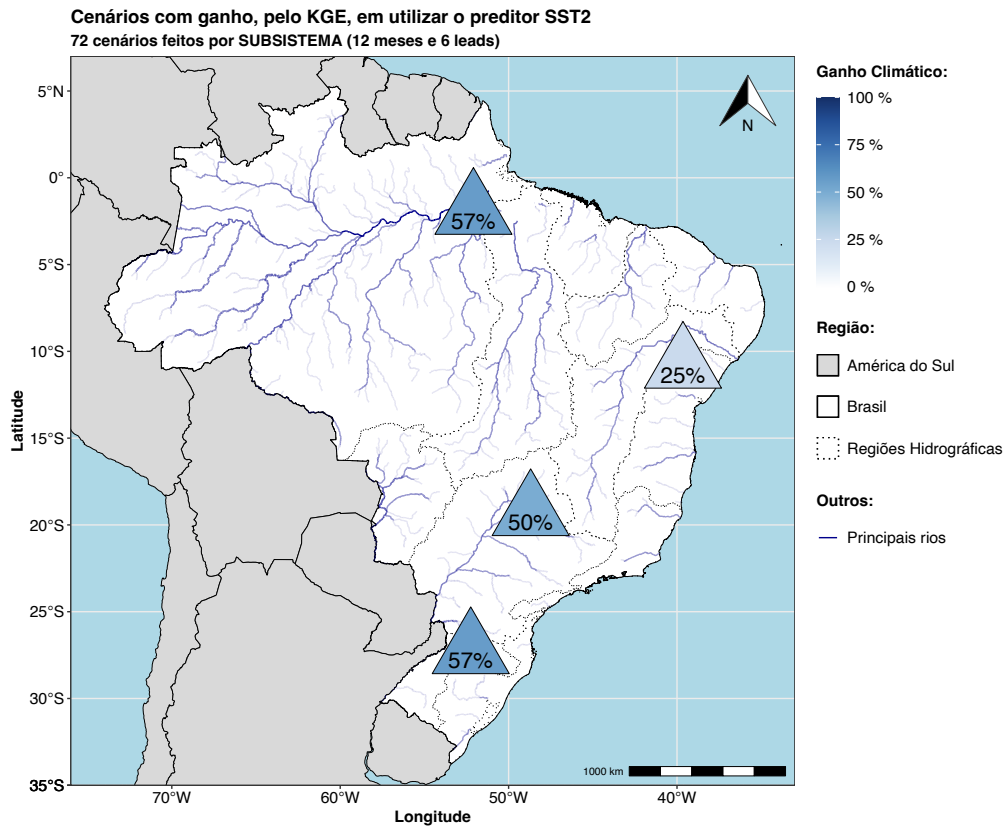


Figura 6.26 Ganho do uso do preditor SST2 nas previsões por subsistemas

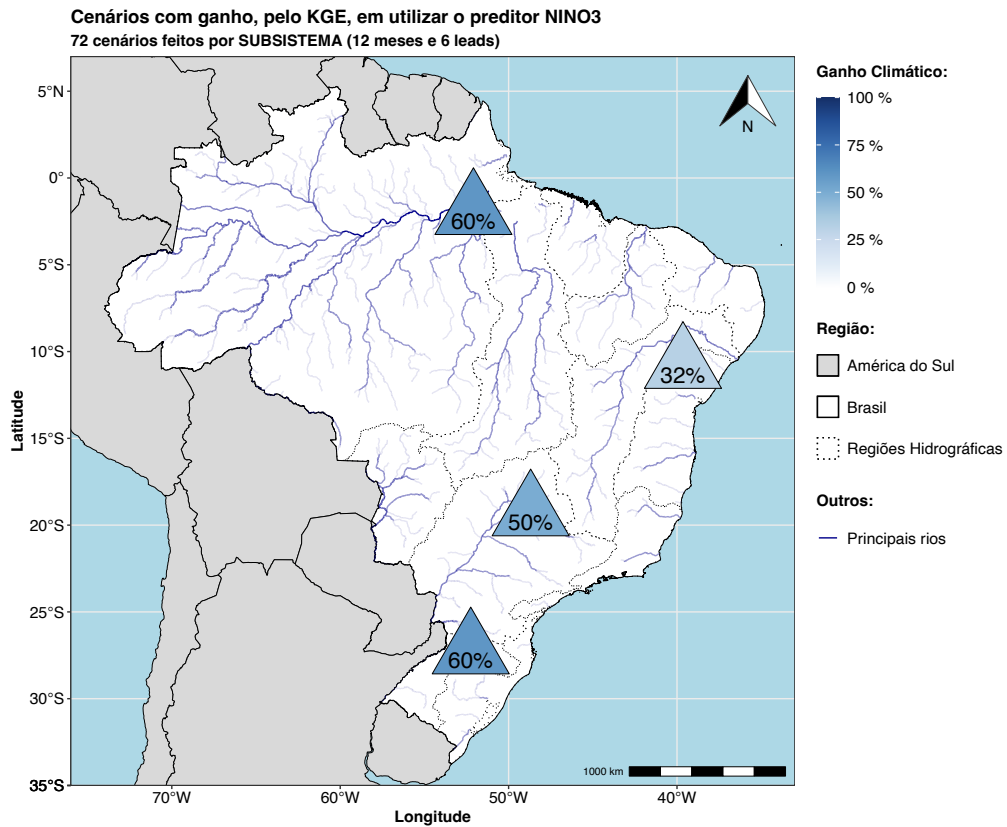


Figura 6.27 Ganho do uso do preditor NINO3 nas previsões por subsistemas

6.6 COMENTÁRIOS GERAIS

A cerca dos resultados mostrados neste capítulo, algumas pontuações são importantes para compreender melhor o que foi feito e cuidados para que os resultados não sejam interpretados de maneira equivocada. Como demonstrado durante o capítulo, a definição de qual métrica utilizar para avaliar os modelos é essencial e pode alterar o tipo de resultado obtido (apesar de não se esperar mudanças drásticas).

A escolha aqui do NSE e KGE se deu por diferentes motivações. Uma sendo que utilizar indicadores que mantivessem a unidade sendo avaliada, como o RMSE, poderia ser problemático por dois casos. Um sendo que pela vasta quantidade de UHEs, se tornaria difícil a comparação (um erro de 10 m³/s em Itaipu não é o mesmo que um erro de 10 m³/s em uma hidroelétrica menor). O outro caso é que usamos no trabalho também o conceito de REE e subsistemas, onde as unidades são outras (MWmed), não podendo comparar, portanto, os resultados das UHEs com dos REEs ou subsistemas.

Esses problemas são resolvidos por métricas como o NSE e KGE. Porém não existe na literatura uma métrica perfeita e universal. Apesar dessa vantagem do NSE/KGE, uma desvantagem é que se torna difícil interpretar a significância de um ganho. Modelos negativos são extremamente ruins enquanto modelos próximos a 1 são os melhores e, apesar de existir uma investida na literatura em tentar definir limiares para definição de modelos aceitáveis e bons, não há consenso. Em especial, não existe um consenso em o que seria um “bom” ganho. Melhorar 0,2 no NSE utilizando algum indicador climático traz apenas uma informação concreta: a métrica foi melhorada. Não necessariamente um ganho de 0,2 é duas vezes melhor que um ganho de 0,1 – com esse segundo sendo possivelmente preferível.

Como o objetivo dessa dissertação é fazer uma comparação com modelos utilizados na parte operacional do ONS, o importante é, de fato, o que métricas como o NSE e KGE reportam – se há ganho ou não e se um modelo é notoriamente “ruim”, tendo valores negativos. Além disso, é possível comparar UHEs com REEs e subsistemas (todos estão na mesma escala de $-\infty$ até 1). Além disso, essas métricas podem ser escritas por 3 componentes cada (α , r , β_{NSE} e β_{KGE}), trazendo uma informação interessante a respeito da melhora – se as informações climáticas melhoram a variância, correlação ou média das simulações feitas.

7. CONCLUSÕES

O propósito deste trabalho foi avaliar se há benefício em utilizar indicadores climáticos nas previsões de vazões em 157 hidroelétricas pertencentes ao SIN (Sistema Interligado Nacional) e quantificar este ganho (denominado aqui de ganho climático). Além da avaliação ser feita em UHEs (Usinas Hidrelétricas) individuais, ela também foi realizada para os 12 REEs (Reservatórios Equivalentes de Energia) e 4 subsistemas existentes no SIN. Para realizar isso, foi proposta e seguida uma metodologia automatizada (programada em R) com potencial de replicação facilitada.

Foram simuladas as séries históricas utilizando três indicadores climáticos, denominados U1, SST2 e NINO3 referentes, respectivamente, aos ventos zonais na região sudeste e litorânea do Brasil, das temperaturas da superfície do mar de parte do oceano Atlântico e das temperaturas da superfície do mar de parte do oceano Pacífico. Também foi proposto o uso de dois tipos de modelos para incorporar esses preditores, um modelo PARX e uma regressão RIDGE. As previsões simuladas foram avaliadas com os dados entre 2010 e 2021, para cada mês e com horizontes de previsões de 1 a 6 meses a frente utilizando as métricas de NSE e KGE definidas pelas suas componentes α , r , β_{NSE} e β_{KGE} propostas por Gupta et al., 2009.

De uma maneira geral, as simulações feitas pelo KGE se mostraram quase sempre superiores as simulações pelo NSE. Isso possivelmente ocorre pelo fato de que nem sempre uma melhora das três componentes causa uma melhora no NSE, pois ele é máximo quando $\alpha = r$ e não quando $\alpha = 1$ (ponto ótimo) – apesar de isso ser apenas uma hipótese uma vez que essas métricas são estimadores de eficiência diferentes. Independente, esses resultados conseguem mostrar quão significativa uma escolha das métricas para avaliação pode ser, causando variações nos resultados e deve, portanto, ser sempre definida com cuidado.

Verificou-se que, quando os resultados são avaliados pelos diferentes meses (agregando então diferentes horizontes de previsões), há um ganho notável em quase todas componentes. Além disso, é notado certo comportamento sazonal, com certos meses conseguindo uma melhora mais frequente nas componentes usadas.

Com os resultados agregados pelos próprios meses (avaliando então os diferentes horizontes de previsão), nota-se que, ao contrário do esperado, o ganho não decai com o aumento do *lead time* das previsões. Uma explicação para isso é que, pela metodologia aplicada aqui, o *lag* utilizado no preditor climático está preso ao horizonte de previsão (previsão 1 mês a frente usa o indicador de um mês atrás, mesmo que seja melhor utilizar algum anterior). Para confirmar isso, mais estudos são necessários e foram feitas recomendações para trabalhos futuros nesse sentido.

A variação da densidade de pontos é clara, especialmente na componente α . Mesmo com o ganho mostrado, pelas densidades dos valores de α por modelo, ainda é visível que há possibilidade para melhorar ainda mais o valor dessa componente. Esse ganho, por seu equacionamento, significa uma melhor representação da variância da simulação (se aproximando da variância observada). Dessa forma, pode-se dizer que a inclusão dos indicadores climáticos comentados, consegue melhorar o entendimento dessa variância das séries mensais de vazões avaliadas. O mesmo não pode ser dito para os valores de r , β_{NSE} e β_{KGE} – que apesar de também serem visíveis, estão mais próximos de seus valores ótimos.

Em relação a localização desse ganho climático, representado pelo número de cenários em que o modelo PARX ou RIDGE obteve valores de KGE (NSE) superiores ao modelo PAR, foram feitos mapas para auxiliarem nessa visualização. Esses mapas foram mais representativos nas avaliações dos REEs e dos subsistemas por esses existirem em menores quantidades – 12 e 4, respectivamente, em comparação com as 157 UHEs.

O ganho climático foi maior no Norte e Sul do Brasil, com o Nordeste e o Sudeste/Centro-Oeste não tendo ganhos tão altos. É importante ressaltar que mesmo assim esses ganhos existem e são relevantes – o pior ganho sendo de 47% (para o REE Sudeste) e 49% (subsistema Nordeste). Isso significa que em quase metade dos cenários avaliados (12 meses e previsões mensais de até 6 meses a frente) existe um ganho (pelo KGE) ao utilizar os preditores climáticos. Isso significa que caso haja uma melhora na escolha dos *lags* dos indicadores (não ficando preso aos *leads*) e em meses específicos, esse ganho pode ser maior.

Sobre a importância dos indicadores, foi avaliado o ganho quando o modelo PARX utiliza apenas um dentre os três preditores climáticos propostos. Esse impacto de cada indicador se mostrou complexo. Primeiramente, como existem relações entre eventos climáticos de larga

escala e, portanto, entre indicadores desses eventos, esses aumentos não são simplesmente aditivos. Por essa relação entre eles ser não linear e complicada, avaliar o ganho que cada indicador traz ao ser incorporado no modelo se mostrou difícil.

Há também variações entre a relevância de cada indicador quando agrupamos as UHEs por REE ou por subsistema. Por exemplo, o indicador SST2 foi o predominante quando avaliando os REEs (sendo o indicador com maiores ganhos climáticos em 7 dos 12 existentes), porém, ao avaliar os subsistemas ele não conseguiu trazer um ganho maior do que os outros indicadores (U1 e NINO3) em nenhum dos 4 subsistemas.

Comum aos REEs e aos subsistemas, porém, é a dificuldade em conseguir um sinal melhor no Nordeste e partes do Sudeste/Centro-Oeste. Para melhorar esses ganhos nessas localidades foram feitas recomendações para trabalhos futuros (apesar da presente dissertação conseguir um ganho nesses locais, porém não tão significativos quanto outros).

Em suma, este estudo se mostrou capaz de cumprir com os objetivos propostos. Foram desenvolvidos 3 modelos para previsões de vazões. Com 2 deles, o PARX e o RIDGE, conseguindo incorporar variáveis exógenas além de apenas utilizar parte da série histórica observada (modelo estocástico PAR). O uso dos três indicadores climáticos (U1, SST2 e NINO3) se demonstraram importantes para diferentes regiões, sendo essencial a agregação em REE ou subsistemas para melhor localização desse ganho e melhor entendimento das relações entre os indicadores e ganho nas previsões de vazões mensais.

Como recomendações futuras, sugere-se avaliar as previsões separando o *lag* dos preditores ao *lead* das previsões. É interessante também otimizar a busca pelo valor de lambda no modelo RIDGE. Por fim, recomenda-se a busca de novos indicadores climáticos, em especial aqueles que possam melhorar as previsões no Nordeste e Sudeste/Centro-Oeste. Destaca-se ainda que previsões numéricas de chuva na escala sazonal podem ser também utilizadas nos modelos propostos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Akaike, H. (1992). Information theory and an extension of the maximum likelihood principle. In *Selected papers of hirotugu akaike* (pp. 199-213). Springer, New York, NY.
- Anctil, F.; Lauzon, N. (2004). Generalisation for neural networks through data sampling and training procedures, with applications to streamflow predictions. *Hydrology and Earth System Sciences Discussions, European Geosciences Union*, 2004, 8 (5), pp. 940-958. fahal-00304974
- Arnold, J. G.; Allen, P. M.; Muttiah, R.; Bernhardt, G. (1995). Automated base flow separation and recession analysis techniques. *Groundwater*, 33(6), 1010-1018.
- Arvanitidits, N. V.; Rosing, J. (1970). Composite representation of a multireservoir hydroelectric power system. *IEEE Transactions on Power Apparatus and Systems*, (2), 319-326.
- Botsis, D.; Latinopouloa, P.; Diamantarab, K. (2018). Comparison of stochastic and machine learning models in streamflow forecasting. *International Conference Protection and Restoration of the Environment XIV*. ISBN: 978-960-99922-4-4.
- Berk, R. A. (2020). *Statistical Learning from a Regression Perspective*. (3rd ed., p. 433). New York: Springer. DOI: <https://doi.org/10.1007/978-3-030-40189-4>
- Box, G. E. P.; Cox, D. R. (1964). 'An analysis of transformations', *Journal of the Royal Statistical Society, Series B*, 26, 211-252.
- Box, G. E. P.; Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day Inc. 589 p.
- Brandão, J. L. B. (2010). Performance of the equivalent reservoir modelling technique for multi-reservoir hydropower systems. *Water resources management*, 24(12), 3101-3114.
- Brasil. (2021). 2º Boletim de Monitoramento do Plano Nacional de Segurança Hídrica. Ministério do Desenvolvimento Regional e Agência Nacional de Águas e Saneamento Básico.
- Breiman, L. (1996a). Bagging predictors. *Machine learning*, 24(2), 123-140.
- Breiman, L. (1996b). Stacked regressions. *Machine learning*, 24(1), 49-64.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Brutsaert, W. (2010). *Hydrology: an introduction*. 5th printing. Cambridge University

- Press. 605 p.
- Burnham, K. P.; Anderson, D. R. (2002). Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach. 2nd Ed. Springer. 515 p.
- CEPEL (2015). Modelo de Previsão de Vazões Semanais Afluentes aos Aproveitamentos Hidroelétrico do Sistema Brasileiro. Versão 6.1 – Manual de Metodologia. CEPEL, Brasil. 45 p.
- CEPEL (2018). Modelo DECOMP: Determinação da Coordenação da Operação a curto Prazo – Manual de Referência. CEPEL, Brasil. 89 p.
- CEPEL (2019). Manual de Referência: Modelo NEWAVE. CEPEL, Brasil. 106 p.
- CNRH, Resolução nº 32, de 15 de outubro de 2003, do Conselho Nacional de Recursos Hídricos; “Institui a Divisão Hidrográfica Nacional”; publicada no Diário Oficial da União em 17/12/2003; Brasília, DF.
- Costa, F. S.; Maceira, M. E. P.; Damázio, J. M. (2007). Modelos de Previsão Hidrológica Aplicados ao Planejamento da Operação do Sistema Elétrico Brasileiro. RBRH — Revista Brasileira de Recursos Hídricos Volume 12 n.3 Jul/Set 2007, 21-30.
- Costa, M. D. S.; Oliveira-Júnior, J. F. D.; Santos, P. J. D.; Correia Filho, W. L. F.; Gois, G. D.; Blanco, C. J. C.; Teodoro, P. E.; Junior, C. A. S.; Santiago, D. B.; Souza, E. O.; Jardim, A. M. D. R. F. (2021). Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño–Southern Oscillation. *International Journal of Climatology*, 41, E2111-E2135. DOI: 10.1002/joc.6835.
- Dantas, L. G.; dos Santos, C. A.; Olinda, R. A. D.; de Brito, J. I.; Santos, C. A.; Martins, E. S.; Oliveira, G.; Brunsell, N. A. (2020). Rainfall Prediction in the State of Paraíba, Northeastern Brazil Using Generalized Additive Models. *Water*, 12(9), 2478.
- De Livera, A. M.; Hyndman, R. J.; Snyder, R. D. (2011). Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American statistical association*, 106(496), 1513-1527.
- Deser, C.; Alexander, M. A.; Xie, S. P.; Phillips, A. S. (2010). Sea surface temperature variability: Patterns and mechanisms. *Annual review of marine science*, 2, 115-143.
- Erdal, H. I.; Karakurt, O. (2013). Advancing monthly streamflow prediction accuracy of CART models using ensemble learning paradigms. *Journal of Hydrology* 477, 119-128.
- de Faria, F. A.; Jaramillo, P. (2017). The future of power generation in Brazil: An

- analysis of alternatives to Amazonian hydropower development. *Energy for Sustainable Development*, 41, 24-35.
- Fu, J. C.; Huang, H. Y.; Jang, J. H.; Huang, P. H. (2019). River stage forecasting using multiple additive regression trees. *Water Resources Management*, 33(13), 4491-4507.
- Golub, G. H.; Heath, M.; Wahba, G. (1979). Generalized Cross-Validation as a Method for Choosing a Good Ridge Parameter. *Technometrics*. 21:2, 215-223. DOI: <https://doi.org/10.1080/00401706.1979.10489751>
- Guilhon, L. G. F.; Rocha, V. F.; Moreira, J. C. (2007). Comparação de métodos de previsão de vazões naturais afluentes a aproveitamentos hidroelétricos. *Revista Brasileira de Recursos Hídricos*, 12(3), 13-20.
- Gupta, H. V.; Kling, H.; Yilmaz, K. K.; Martinez, G. F. (2009) Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, 377(1-2), 80-91.
- Hipel, K. W.; McLeod, A. I. (1994). *Time series modelling of water resources and environmental systems*. Elsevier. 1050 p.
- Hyndman, R. J.; Koehler, A. B.; Snyder, R. D.; Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of forecasting*, 18(3), 439-454.
- Hyndman, R. J.; Athanasopoulos, G. (2021). *Forecasting: principles and practice*, 3rd edition. OTexts: Melbourne, Australia. OTexts.com/fpp3. Último acesso em <17/05/2021>.
- International Energy Agency, IEA (2020). Electricity Generation by source, Brazil 1990-2019. [S.I.]. Disponível em: < <https://www.iea.org/data-and-statistics?country=BRAZIL&fuel=Electricity%20and%20heat&indicator=ElecGenByFuel> >. Acesso em 06 out. 2020.
- James, G.; Witten, D.; Hastie, T.; Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. (1st ed., p. 426). New York: Springer. DOI: <https://doi.org/10.1007/978-1-4614-7138-7>
- Kaplan, A.; Cane, M. A.; Kushnir, Y.; Clement, A. C.; Blumenthal, M. B.; Rajagopalan, B. (1998). Analyses of global sea surface temperature 1856-1991. *Journal of Geophysical Research: Oceans*. 103(C9), 18567-18589.
- Karakurt, O.; Erdal, H. I.; Namli, E.; Yumurtaci Aydogmus, H.; TURKKAN, Y. S.

- (2013). Comparing ensembles of decision trees and neural networks for one-day ahead streamflow prediction. *Scientific Research Journal, I (IV)*, 43-55.
- Kwiatkowski, D.; Phillips, P. C.; Schmidt, P.; Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?. *Journal of econometrics*, 54(1-3), 159-178.
- Kayano, M. T.; Andreoli, R. V.; de Souza, R. A. (2020). Pacific and Atlantic multidecadal variability relations to the El Niño events and their effects on the South American rainfall. *International Journal of Climatology*, 40(4), 2183-2200.
- Knoben, W. J.; Freer, J. E.; Woods, R. A. (2019). Inherent benchmark or not? Comparing Nash–Sutcliffe and Kling–Gupta efficiency scores. *Hydrology and Earth System Sciences*, 23(10), 4323-4333. <https://doi.org/10.5194/hess-23-4323-2019>
- Lamontagne, J. R.; Barber, C. A.; Vogel, R. M. (2020). Improved estimators of model performance efficiency for skewed hydrologic data. *Water Resources Research*, 56(9), e2020WR027101. DOI: <https://doi.org/10.1029/2020WR027101>
- Lappicy, T.; Lima, C. H. R.; Fiorucci, J. A. (2021). Uso de modelos estocásticos para previsões de vazões mensais dos reservatórios ligados ao SIN utilizando o conceito de Energia Equivalente. *XXIV Simpósio Brasileiro de Recursos Hídricos*.
- Li, P. H.; Kwon, H. H.; Sun, L.; Lall, U.; Kao, J. J. (2010). A modified support vector machine based prediction model on streamflow at the Shihmen Reservoir, Taiwan. *International Journal of Climatology*, 30(8), 1256-1268.
- Li, Y.; Liang, Z.; Hu, Y.; Li, B.; Xu, B.; Wang, D. (2020). A multi-model integration method for monthly streamflow prediction: modified stacking ensemble strategy. *Journal of Hydroinformatics*, 22(2), 310-326.
- Lima, D. R. M. D. (2018). Previsão de vazões afluentes a usinas hidrelétricas aplicada à programação da operação do sistema elétrico brasileiro. Dissertação de Doutorado, Universidade de São Paulo. 140 p.
- Lima, C. H.; Lall, U. (2010a). Climate informed monthly streamflow forecasts for the Brazilian hydropower network using a periodic ridge regression model. *Journal of hydrology*, 380(3-4), 438-449.

- Lima, C. H.; Lall, U. (2010b). Climate informed long term seasonal forecasts of hydroenergy inflow for the Brazilian hydropower system. *Journal of hydrology*, 381(1-2), 65-75.
- Ljung, G. M.; Box, G. E. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.
- Maceira, M. E. P.; Damázio, J. M.; Ghirardi, A. O.; Dantas, H. M. (1999). Periodic ARMA models applied to weekly streamflow forecasts. In *PowerTech Budapest 99. Abstract Records. (Cat. No. 99EX376)* (p. 86). IEEE.
- Maceira, M. E. P.; Duarte, V. S.; Penna, D. D. J.; Moraes, L. A. M.; Melo, A. C. G. (2008). Ten years of application of stochastic dual dynamic programming in official and agent studies in Brazil-description of the newwave program. *16th PSCC, Glasgow, Scotland*, 14-18.
- Maceira, M. E. P.; Penna, D. D. J.; Diniz, A. L.; Pinto, R. J.; Melo, A. C. G.; Vasconcellos, C. V.; Cruz, C. B. (2018). Twenty years of application of stochastic dual dynamic programming in official and agent studies in Brazil main features and improvements on the NEWAVE model. In *2018 power systems computation conference (PSCC)* (pp. 1-7). IEEE.
- Maidment, D. R. (1993) *Handbook of hydrology*. McGraw-Hill, New York.
- Marchau, V. A. W. J.; Walker, W. E.; Bloemen, P. J. T. M.; Popper, S. W. (2019). Capítulo 1 – Introdução. In: *Decision Making under Deep Uncertainty: From theory to practice*. Springer Nature, 405 p.
- MME – Ministério de Minas e Energia. (2017). Memórias da Reunião com a CPAMP – Comissão Permanente para Análise de Metodologias e Programas Computacionais do Setor Elétrico. Dia: 06 de dezembro de 2017, 11h. Disponível em: <https://www.gov.br/mme/pt-br/assuntos/conselhos-e-comites/cpamp/2017/ata-reuniao-cpamp-06-12-2017-com-anexos.pdf>. Acesso 05 de julho de 2021.
- MME – Ministério de Minas e Energia. (2020). [S.I.] Sistema de Informações Energéticas Relatório da Matriz de Balanço Energético. Disponível em: http://www.mme.gov.br/SIEBRASIL/consultas/visor_reportes_be.aspx?or=520&ss=2&v=1. Acesso em: 06 de out. 2020.
- Moradi, A. M.; Dariane, A. B.; Yang, G.; Block, P. (2020). Long-range reservoir inflow forecasts using large-scale climate predictors. *International Journal of Climatology*.
- Moriasi, D. N.; Arnold, J. G.; Van Liew, M. W.; Bingner, R. L.; Harmel, R. D.; Veith,

- T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Nash, J. E.; Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology*, 10(3), 282-290.
- Neslihanoglu, S.; Ünal, E.; Yozgatlıgil, C. (2021). Performance comparison of filtering methods on modelling and forecasting the total precipitation amount: a case study for Muğla in Turkey. *Journal of Water and Climate Change*.
- Oliveira, V. G. D.; Lima, C. H. R. (2016). Previsões multiescala de vazões para o sistema hidrelétrico brasileiro utilizando ponderação bayesiana de modelos (BMA). *RBRH*, 21, 618-635.
- Oliveira, F. J. A. (2020). Planejamento da operação energética no sistema: conceitos, modelagem matemática, previsão de geração e carga. São Paulo: *Artliber*, 2020. 402 p.
- ONS – Operador Nacional do Sistema Elétrico (2022). Atualização de Séries Históricas de Vazões – Período 1931 a 2021. Disponível pelo portal sintegre em: <https://sintegre.ons.org.br/> ao pesquisar “Série Histórica de Vazões Naturais”.
- ONS – Operador Nacional do Sistema Elétrico. (2021a). *Sobre o SIN: O Sistema em Números*. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>. Último acesso 12 de julho de 2021.
- ONS – Operador Nacional do Sistema Elétrico. (2021b). *Sobre o SIN: Sistemas Isolados*. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/sistemas-isolados>. Último acesso 05 de julho de 2021.
- ONS – Operador Nacional do Sistema Elétrico. (2020). Site com dados cadastrais e série histórica dos reservatórios despachados pela ONS. Disponível em: <http://aplicam.ons.org.br/hidrologia/>. Acesso em: 24 de nov. de 2020.
- ONS – Operador Nacional do Sistema Elétrico. (2010). Operação do Sistema Interligado Nacional: Relatório Anual de Avaliação das Previsões de Vazões – 2010. Brasília: ONS, 2010. 230 p.
- Papacharalampous, G.; Tyralis, H.; Koutsoyiannis, D. (2018). Predictability of monthly temperature and precipitation using automatic time series forecasting methods. *Acta Geophysica*, 66(4), 807-831.
- Pham, L. T.; Luo, L.; Finley, A. (2021). Evaluation of random forests for short-term daily streamflow forecasting in rainfall-and snowmelt-driven-watersheds. *Hydrology and Earth System Sciences*, 25(6), 2997-3015.

- Razali, N. M.; Wah, Y. B. (2011). Power comparisons of shapiro-wilk, Kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of statistical modeling and analytics*, 2(1), 21-33.
- R Development Core Team. (2021). R: A language and environment for statistical computing. Vienna: Austria. Acesso disponível em: <http://www.r-project.org/>
- Reynolds, R. W.; Smith, T. M. (1994). Improved global sea surface temperature analyses using optimum interpolation. *Journal of climate*, 7(6), 929-948.
- Ribeiro, V. H. A.; Reynoso-Meza, G. & Siqueira, H. V. (2020). Multi-objective ensembles of echo state networks and extreme learning machines for streamflow series forecasting. *Engineering Applications of Artificial Intelligence*, 95, 103910.
- Sahu, N.; Behera, S. K.; Ratnam, J. V.; Da Silva, R. V.; Parhi, P.; Duan, W.; Takara, K.; Singh, R. B.; Yamagata, T. (2014). El Nino Modoki connection to extremely-low streamflow of the Paranaiba River in Brazil. *Climate dynamics*, 42, 1509-1516. <https://doi.org/10.1007/s00382-013-2006-3>.
- Salas, J. D.; Deuller, J. W.; Yevjevich, V.; Lane, W. L. (1980). *Applied modeling of hydrologic time series*. Water Resources Publication.
- Santos, E. B.; de Freitas, E. D.; Rafee, S. A. A.; Fujita, T.; Rudke, A. P.; Martins, L. D.; Souza, R. A. F.; Martins, J. A. (2021). Spatio-temporal variability of wet and drought events in the Paraná River basin—Brazil and its association with the El Niño—Southern oscillation phenomenon. *International Journal of Climatology*, 41(10), 4879-4897.
- Schapire, R. E. (1990). The strength of weak learnability. *Machine learning*, 5(2), 197-227.
- Schick, S.; Rössler, O. K.; Weingartner, R. (2016). Comparison of cross-validation and bootstrap aggregating for building a seasonal streamflow forecast model. *Proceedings of the International Association of Hydrological Sciences*, 374, 159-163.
- Serinaldi, F.; Kilsby, C. G.; Lombardo, F. (2018). Untenable nonstationarity: An assessment of the fitness for purpose of trend tests in hydrology. *Advances in Water Resources*, 111, 132-155. <https://doi.org/10.1016/j.advwatres.2017.10.015>
- Shapiro, S. S.; Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4), 591-611.
- Shumway, R.; Stoffer, D. (2019). *Time series: a data analysis approach using R*. CRC

- Press.
- Silveira, C. D. S.; Alexandre, A. M. B.; Souza, F. D. A. D.; Vasconcelos, F. D. C.; Cabral, S. L. (2017). Monthly streamflow forecast for National Interconnected System (NIS) using Periodic Auto-regressive Endogenous Models (PAR) and Exogenous (PARX) with climate information. *RBRH*, 22.
- Simon, P. S. (2016). Aprimoramento do Cálculo das Parcelas de Acoplamento Hidráulico Entre Reservatórios Equivalentes em Problemas de Planejamento Energético de Médio Prazo. Trabalho de conclusão de curso – Rio de Janeiro: UFRJ/ Escola Politécnica, 2016, 91 p.
- Sivakumar, B. (2017). *Chaos in hydrology: bridging determinism and stochasticity*. Springer. 408 p.
- SINDAT – Sistema de Informações Geográficas Cadastrais do SIN (2021). Disponível em: <<http://sindat.ons.org.br/SINDAT/Home/ControleSistema>>. Último acesso: 05 de Julho de 2021.
- Terry, L. A.; Pereira, M. V.; Araripe Neto, T. A.; Silva, L. F. C. A.; Sales, P. R. H. (1986). Coordinating the energy generation of the Brazilian national hydrothermal electrical generating system. *Interfaces*, 16(1), 16-38.
- Tucci, C. E. M. (2005). Modelos Hidrológicos. Segunda Edição. Ed. Universidade UFRGS, ABRH. 678 pg.
- USGS – *United States Geological Survey*. (2019). *The Natural Water Cycle*. Disponível em: < <http://water.usgs.gov/edu/watercycle.html> >. Último acesso: 12 de Julho de 2021.
- Uyanto, S. S. (2020). Power comparisons of five most commonly used autocorrelation tests. *Pakistan Journal of Statistics and Operation Research*, 119-130.
- Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2), 241-259.
- Zachary, H.; Asghar, Z.; Oroza, C. A. (2020). Multi-step Weekly Average Forecasting of Reservoir Storage Volume Using Deep Learning. *Earth and Space Science Open Archive ESSOAr*.
- Zambon, R. C. (2015). A operação dos reservatórios e o planejamento da operação hidrotérmica do Sistema Interligado Nacional. *Revista USP*, (104), 133-144.

APÊNDICES

APÊNDICE A – DETALHES DOS REES E SUBSISTEMAS

Tabela A.1 12 REEs dos 4 Subsistema do SIN

Subsistema	REE
Norte	Amazonas
	Belo Monte
	Norte
Nordeste	Nordeste
Sul	Iguaçu
	Sul
Sudeste/ Centro-Oeste	Itaipu
	Madeira
	Paraná
	Parapanema
	Sudeste
	Teles Pires

Tabela A.2 UHEs do REE Amazonas (Subsistema Norte)

Nome	Posto	Long.	Lat.	Bacia	Est.
Balbina	269	-59,47	-1,92	Amazonas	∇ ¹
Cachoeira Caldeirão	204	-51,29	0,85	Amazonas	✓
Coaracy Nunes	280	-51,26	0,90	Amazonas	∇ ¹
Ferreira Gomes	297	-51,20	0,86	Amazonas	∇ ¹
Santo Antônio Jari	290	-52,52	-0,65	Amazonas	✓

Tabela A.3 UHEs do REE Belo Monte (Subsistema Norte)

Nome	Posto	Long.	Lat.	Bacia	Est.
Belo Monte	292	-51,80	-3,12	Amazonas	✓
Curuá-Una	277	-54,30	-2,81	Amazonas	✓

Tabela A.4 UHEs do REE Norte (Subsistema Norte)

Nome	Posto	Long.	Lat.	Bacia	Est.
Estreito	271	-47,46	-6,59	Tocantins-Araguaia	✓
Pimental	288	-51,95	-3,44	Amazonas	✓
Tucuruí + Tucuruí II	275	-49,64	-3,83	Tocantins-Araguaia	✓

Tabela A.5 UHEs do REE Nordeste (Subsistema Nordeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Boa Esperança	190	-43,74	-6,71	Parnaíba	∇ ¹
Irapé	255	-42,58	-16,74	Atlântico Leste	∇ ¹
Itaparica	172	-38,31	-9,14	São Francisco	∇ ¹
Itapebi	188	-39,59	15,97	Atlântico Leste	∇ ¹
Moxotó	173	-38,21	-9,36	São Francisco	∇ ¹
Paulo Afonso 1, 2 e 3	*	-38,20	-9,40	São Francisco	∇ ¹
Paulo Afonso 4	*	-38,21	-9,41	São Francisco	∇ ¹
Pedra do Cavalo	254	-39,00	12,59	Atlântico Leste	∇ ¹
Sobradinho	169	-40,83	-9,43	São Francisco	∇ ¹
Xingó	178	-37,80	-9,63	São Francisco	∇ ¹

* Para mais detalhes sobre esse posto, verificar nos dados oficiais do ONS

Tabela A.6 UHEs do REE Iguaçu (Subsistema Sul)

Nome	Posto	Long.	Lat.	Bacia	Est.
Baixo Iguaçu	81	-53,67	25,51	Paraná	∇ ¹
Foz do Areia	74	-51,67	26,01	Paraná	∇ ¹
Fundão	72	-52,04	25,72	Paraná	∇ ¹
Gov. José Richa	222	-53,50	25,54	Paraná	∇ ¹
Jordão	73	-52,09	25,76	Paraná	∇ ¹
Mauá	57	-50,71	24,06	Paraná	∇ ¹
Salto Osório	78	-53,01	25,54	Paraná	∇ ¹
Salto Santiago	77	-52,62	25,63	Paraná	∇ ¹
Santa Clara – PR	71	-51,97	25,67	Paraná	∇ ¹
Segredo	76	-52,11	25,79	Paraná	∇ ¹

Tabela A.7 UHEs do REE Sul (Subsistema Sul)

Nome	Posto	Long.	Lat.	Bacia	Est.
14 De Julho	284	-51,67	-29,06	Atlântico Sul	∇ ¹
Barra Grande	215	-51,19	-27,78	Uruguai	∇ ¹
Campos Novos	216	-51,33	-27,60	Uruguai	∇ ¹
Capivari Cachoeira	115	-48,76	-25,25	Atlântico Sul	∇ ¹
Castro Alves	98	-51,46	-29,02	Atlântico Sul	∇ ¹
Dona Francisca	114	-53,28	-29,45	Atlântico Sul	✓
Ernestina	110	-52,55	-28,56	Atlântico Sul	∇ ¹
Foz Do Chapecó	94	-53,04	-27,14	Uruguai	∇ ¹
Garibaldi	89	-51,00	-27,64	Uruguai	∇ ¹
Itá	92	-52,38	-27,28	Uruguai	∇ ¹
Itaúba	113	-53,24	-29,26	Atlântico Sul	∇ ¹
Jacuí	112	-53,23	-29,08	Atlântico Sul	✓
Machadinho	217	-51,79	-27,53	Uruguai	∇ ¹
Monjolinho	220	-52,73	-27,35	Uruguai	∇ ¹
Monte Claro	97	-51,53	-29,02	Atlântico Sul	∇ ¹
Passo Fundo	93	-52,74	-27,55	Uruguai	∇ ¹
Passo Real	111	-53,19	-29,02	Atlântico Sul	✓
Passo São João	103	-55,05	-28,13	Uruguai	∇ ¹
Quebra-Queixo	286	-52,56	-26,67	Uruguai	∇ ¹
Salto Pilão	101	-49,47	-27,10	Atlântico Sul	∇ ¹
São José	102	-54,82	-28,18	Uruguai	∇ ¹
São Roque	88	-50,81	-27,50	Uruguai	∇ ¹

Tabela A.8 UHEs do REE Itaipu (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Itaipu	266	-54,59	-25,41	Paraná	∇ ¹

Tabela A.9 UHEs do REE Madeira (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Dardanelos	291	-59.45	10.16	Amazonas	✓
Guaporé	296	-58.98	15.14	Amazonas	∇ ¹
Jirau	285	-64.64	-9.27	Amazonas	✓
Rondon II	145	-60.70	11.97	Amazonas	✓
Samuel	279	-63.46	-8.75	Amazonas	✓
Santo Antônio	287	-63.95	-8.80	Amazonas	∇ ¹

Tabela A.10 UHEs do REE Paraná (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Água Vermelha	18	-50,35	-19,87	Paraná	✓
Armando de Salles Oliveira	16	-47,01	-21,63	Paraná	∇ ¹
Bariri	238	-48,75	-22,15	Paraná	✓
Barra Bonita	237	-48,53	-22,52	Paraná	✓
Barra Dos Coqueiros	248	-51,00	-18,72	Paraná	✓
Batalha	22	-47,50	-17,35	Paraná	✓
Cachoeira Dourada	32	-49,49	-18,50	Paraná	✓
Caconde	14	-46,62	-21,57	Paraná	✓
Caçu	247	-51,15	-18,53	Paraná	✓
Camargos	1	-44,62	-21,32	Paraná	∇ ¹
Capim Branco 1	207	-48,16	-18,78	Paraná	∇ ¹
Capim Branco 2	28	-48,44	-18,66	Paraná	∇ ¹
Corumbá I	209	-48,53	-17,99	Paraná	∇ ¹
Corumbá III	23	-47,94	-16,79	Paraná	✓
Corumbá IV	205	-48,18	-16,32	Paraná	∇ ¹
Euclides Da Cunha	15	-46,95	-21,60	Paraná	∇ ¹
Edgard De Souza	161	-46,91	-23,45	Paraná	∇ ¹
Emborcação	24	-47,99	-18,45	Paraná	∇ ¹
Espora	99	-51,87	-18,68	Paraná	∇ ¹
Foz Do Rio Claro	261	-50,65	-19,12	Paraná	✓
Funil – Grande	211	-45,04	-21,14	Paraná	∇ ¹
Furnas	6	-46,32	-20,67	Paraná	∇ ¹
Ibitinga	239	-48,99	-21,76	Paraná	∇ ¹
Igarapava	10	-47,76	-19,99	Paraná	✓
Ilha Solteira	34	-51,37	-20,38	Paraná	✓
Itumbiara	31	-49,10	-18,41	Paraná	∇ ¹
Itutinga	2	-44,63	-21,29	Paraná	✓
Jaguara	9	-47,43	-20,02	Paraná	✓
Jupia	245	-51,63	-20,78	Paraná	∇ ¹
Luis Carlos Barreto	8	-47,28	-20,15	Paraná	✓
Marimbondó	17	-49,20	-20,30	Paraná	✓
Mascarenhas De Moraes	7	-47,06	-20,29	Paraná	∇ ¹
Miranda	206	-48,04	-18,91	Paraná	∇ ¹
Nova Avanhandava	242	-50,20	-21,12	Paraná	∇ ¹
Nova Ponte	25	-47,70	-19,13	Paraná	∇ ¹
Pedreira	*	-46,67	-23,70	Paraná	∇ ¹

Ponte Nova	*	-45,88	-23,57	Paraná	∇ ¹
Porto Colômbia	12	-48,57	-20,13	Paraná	✓
Porto Primavera	246	-52,96	-22,48	Paraná	∇ ¹
Promissão	240	-49,78	-21,30	Paraná	∇ ¹
Salto	294	-51,17	-18,81	Paraná	✓
Salto Rio Verdinho	241	-50,75	-19,14	Paraná	✓
São Domingos	154	-53,18	-20,06	Paraná	∇ ¹
São Simão	33	-50,50	-19,02	Paraná	∇ ¹
Serra Do Facão	251	-47,68	-18,05	Paraná	∇ ¹
Traição	104	-46,69	-23,60	Paraná	∇ ¹
Três Irmãos	243	-51,30	-20,67	Paraná	✓
Volta Grande	11	-48,22	-20,03	Paraná	✓

* Para mais detalhes sobre esse posto, verificar dados oficiais do ONS

Tabela A.11 UHEs do REE Paranapanema (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Canoas I	52	-50,52	-22,94	Paraná	∇ ¹
Canoas II	51	-50,25	-22,94	Paraná	∇ ¹
Capivara	61	-51,36	-22,66	Paraná	∇ ¹
Chavantes	49	-49,73	-23,13	Paraná	∇ ¹
Jurumirim	47	-49,23	-23,21	Paraná	∇ ¹
Lucas Nogueira Garcez	50	-50,00	-22,90	Paraná	∇ ¹
Ourinhos	249	-49,84	-23,07	Paraná	∇ ¹
Piraju	48	-49,38	-23,15	Paraná	∇ ¹
Rosana	63	-52,87	-22,60	Paraná	✓
Taquaruçu	62	-52,00	-22,54	Paraná	∇ ¹

Tabela A.12 UHEs do REE Sudeste (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Aimorés	148	-50,35	-19,87	Atlântico Sudeste	∇ ¹
Anta	129	-48,53	-22,52	Atlântico Sudeste	✓
Barra Brauna	135	-42,40	-21,45	Atlântico Sudeste	∇ ¹
Baguari	141	-51,00	-18,72	Atlântico Sudeste	∇ ¹
Billings	118	-48,75	-22,15	Paraná	∇ ¹
Cana Brava	191	-47,50	-17,35	Tocantins-Araguaia	∇ ¹
Candongá	149	-49,49	-18,50	Atlântico Sudeste	∇ ¹
Fontes	303	-48,16	-18,78	Atlântico Sudeste	∇ ¹
Funil	123	-48,44	-18,66	Atlântico Sudeste	✓
Guarapiranga	117	-46,62	-21,57	Paraná	∇ ¹
Guilman-Amorim	262	-51,15	-18,53	Atlântico Sudeste	∇ ¹
Henry Borden	318	-44,62	-21,32	Atlântico Sudeste	∇ ¹
Ilha Dos Pombos	130	-48,53	-17,99	Atlântico Sudeste	∇ ¹
Itiquira I	259	-47,94	-16,79	Paraguai	∇ ¹
Itiquira II	252	-48,18	-16,32	Paraguai	∇ ¹
Jaguari	120	-46,95	-21,60	Atlântico Sudeste	∇ ¹
Jauru	295	-46,91	-23,45	Paraguai	∇ ¹
Lajeado	273	-47,99	-18,45	Tocantins-Araguaia	∇ ¹
Lajes	202	-51,87	-18,68	Atlântico Sudeste	✓
Manso	278	-50,65	-19,12	Paraguai	✓
Mascarenhas	144	-45,04	-21,14	Atlântico Sudeste	∇ ¹
Nilo Peçanha	131	-46,32	-20,67	Atlântico Sudeste	∇ ¹
Paraibuna	121	-51,37	-20,38	Atlântico Sudeste	✓
Peixe Angical	257	-48,99	-21,76	Tocantins-Araguaia	∇ ¹
Pereira Passos	306	-47,76	-19,99	Atlântico Sudeste	∇ ¹
Picada	197	-49,10	-18,41	Atlântico Sudeste	∇ ¹
Porto Estrela	263	-47,43	-20,02	Atlântico Sudeste	∇ ¹
Ponte de Pedra	281	-44,63	-21,29	Paraguai	∇ ¹
Queimado	158	-51,63	-20,78	São Francisco	∇ ¹
Retiro Baixo	155	-47,28	-20,15	São Francisco	∇ ¹
Rosal	196	-47,01	-21,63	Atlântico Sudeste	✓
Sá Carvalho	183	-47,06	-20,29	Atlântico Sudeste	∇ ¹
Salto Grande	134	-49,20	-20,30	Atlântico Sudeste	∇ ¹
Santa Branca	122	-48,04	-18,91	Atlântico Sudeste	✓
Santa Cecília	125	-50,20	-21,12	Atlântico Sudeste	✓
Santa Clara – MG	283	-49,78	-21,30	Atlântico Leste	∇ ¹
Santana	203	-47,70	-19,13	Atlântico Sudeste	✓
São Salvador	253	-48,57	-20,13	Tocantins-Araguaia	∇ ¹
Serra Da Mesa	270	-46,67	-23,70	Tocantins-Araguaia	∇ ¹
Simplicio	126	-45,88	-23,57	Atlântico Sudeste	✓
Sobragi	198	-52,96	-22,48	Atlântico Sudeste	∇ ¹
Tócos	201	-47,68	-18,05	Atlântico Sudeste	✓
Três Marias	156	-50,75	-19,14	São Francisco	∇ ¹
Vigário	316	-51,17	-18,81	Atlântico Sudeste	∇ ¹

Tabela A. 13 UHEs do REE Teles Pires (Subsistema Sudeste/Centro-Oeste)

Nome	Posto	Long.	Lat.	Bacia	Est.
Colíder	228	-55,77	-10,98	Amazonas	∇ ¹
Juruena	226	-58,93	-12,85	Amazonas	∇ ¹
São Manoel	230	-57,05	-9,19	Amazonas	✓
Sinop	227	-55,45	-11,28	Amazonas	∇ ¹
Teles Pires	229	-56,78	-9,35	Amazonas	✓

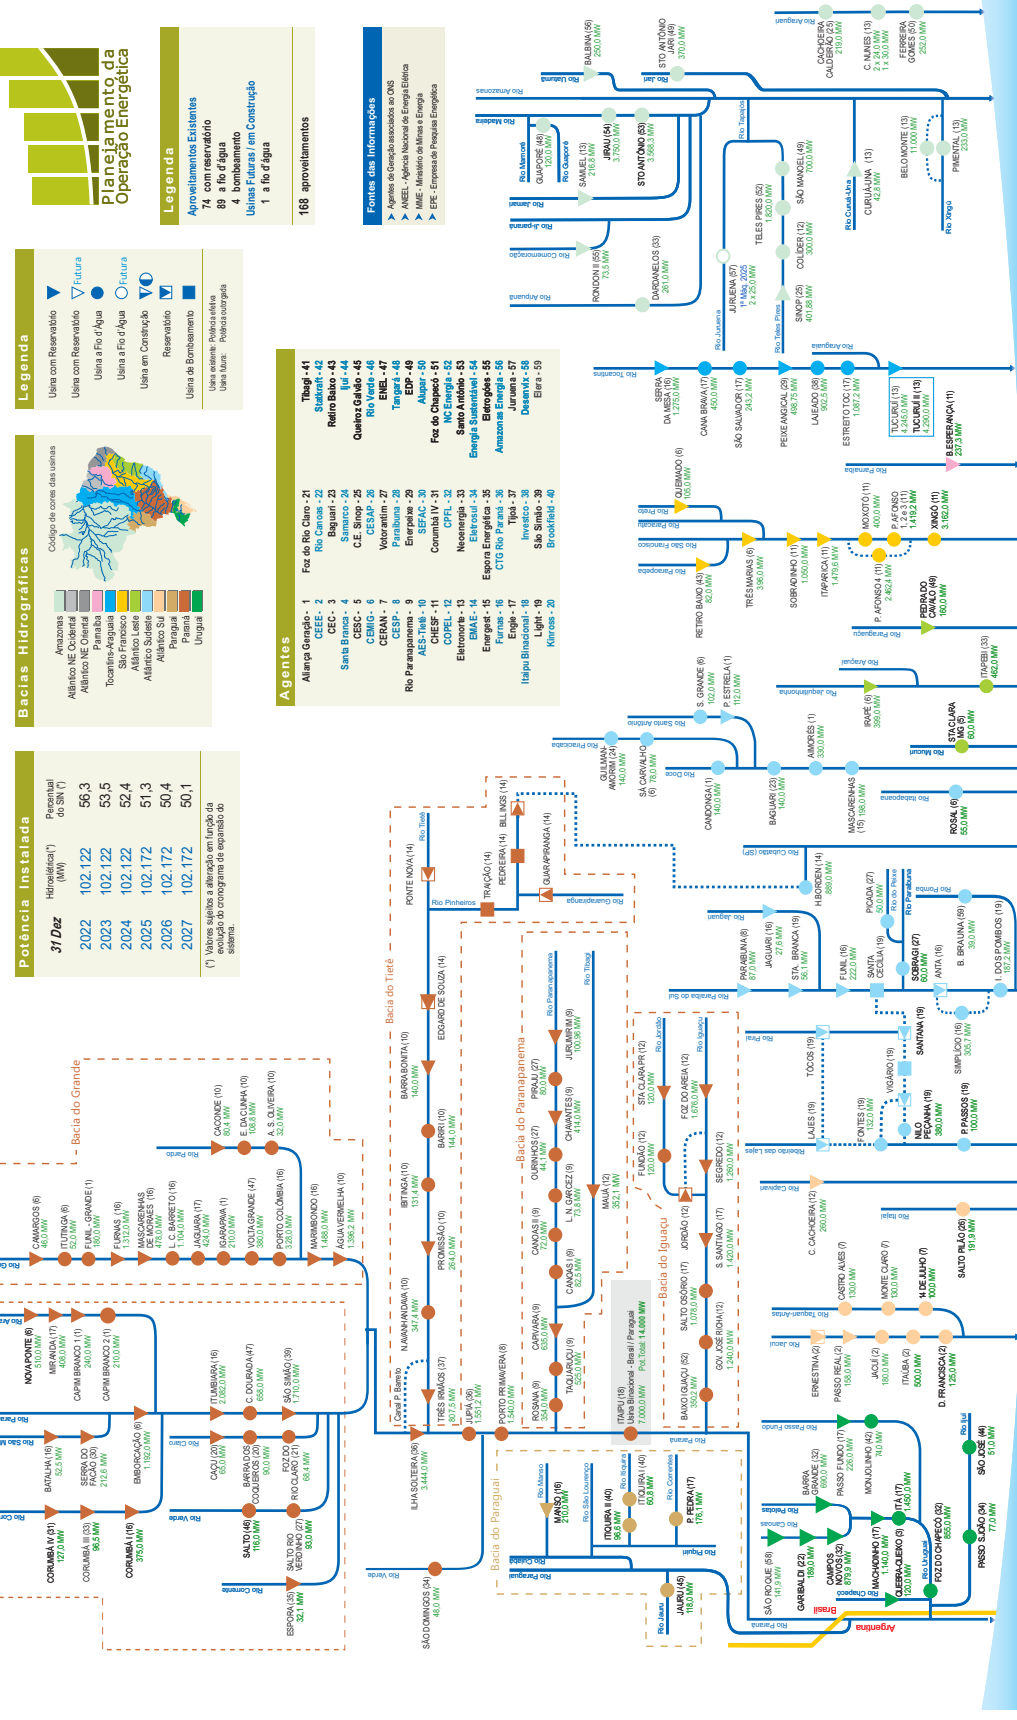
APÊNDICE B – CONFIGURAÇÃO DO SIN

ONS Operador Nacional do Sistema Elétrico

Diagrama Esquemático das Usinas Hidroelétricas do SIN

Usinas Hidroelétricas Despachadas pelo ONS na Otimização do Sistema Interligado Nacional

Horizonte: 2023 - 2027



Planejamento da Operação Energética

Reservatório (blue triangle)
 Usina com Reservatório (blue triangle)
 Usina a Fio d'Água (blue circle)
 Usina a Fio d'Água Futura (blue circle with dashed border)
 Usina em Construção (blue circle with 'C')
 Usina de Bombeamento (blue square)
 Usina existente: Posicionada (blue square)
 Usina Fut.: Posicionada (blue square)

Legenda

Aparelhamentos Existentes: 74 com reservatório, 89 a fio d'água, 4 bombeamento, 1 a fio d'água
 168 aproveitamentos

Bacias Hidrográficas

Código de cores das usinas

- Amazônicas
- Atlântico NE Central
- Atlântico NE Orlado
- Paraná
- Tocantins-Araguaia
- São Francisco
- Adriático Sudeste
- Adriático S4
- Piranguá
- Paraná
- Uruguai

Potência Instalada

31 Dez	Hidroelétrica ⁽¹⁾ (MW)	Parcial do SIN ⁽¹⁾ (MW)
2022	102.122	56,3
2023	102.122	53,5
2024	102.122	52,4
2025	102.172	51,3
2026	102.172	50,4
2027	102.172	50,1

(1) Valores sujeitos a alteração em função da evolução do cronograma de regularização do sistema.

Fontes das Informações

- Agência de Planejamento do ONS
- Agência Nacional de Energia Elétrica
- ANEEL - Ministério de Minas e Energia
- EPE - Empresa de Pesquisa Energética

Agentes

Altaço Grande-1	Foz do Rio Claro-21	Tupã-41
CEEE-2	Rio Canaã-22	Sidetril-42
CEC-3	Biquini-23	Retro Babil-43
Santa Branca-4	Simeão-24	Ita-44
CEMIG-5	CEMIG-25	Queluz-Guarani-45
CEMIG-6	CEMIG-26	Rio Verde-46
CERAN-7	Votorantim-27	EBEL-47
CESEP-8	Paranába-28	Tangará-48
Alto Volta-9	Enxereta-29	EDP-49
Rio Paranapanema-10	Alto Volta-30	NC Energia-50
Alto Volta-11	Comunidade-31	Foz do Chapeleiro-51
CEPEL-12	CEPEL-32	NC Energia-52
Electron-13	Neonenergia-33	Santo Antônio-53
EMAE-14	Neonenergia-34	Energia Sustentável-54
Energ-15	Esopa Energética-35	Elétronal-55
OTG Rio Pinheiros-16	OTG Rio Pinheiros-36	Amazonas-56
Elgê-17	Elgê-37	Juruena-57
Itaipu Binacional-18	Itaipu Binacional-38	Desenv-58
Light-19	São Simão-39	Elira-59
Keros-20	Brookfield-40	

Figura B.1 Configuração do SIN 2023 – 2027

APÊNDICE C – PLANO 3D DO GANHO CLIMÁTICO DOS MODELOS

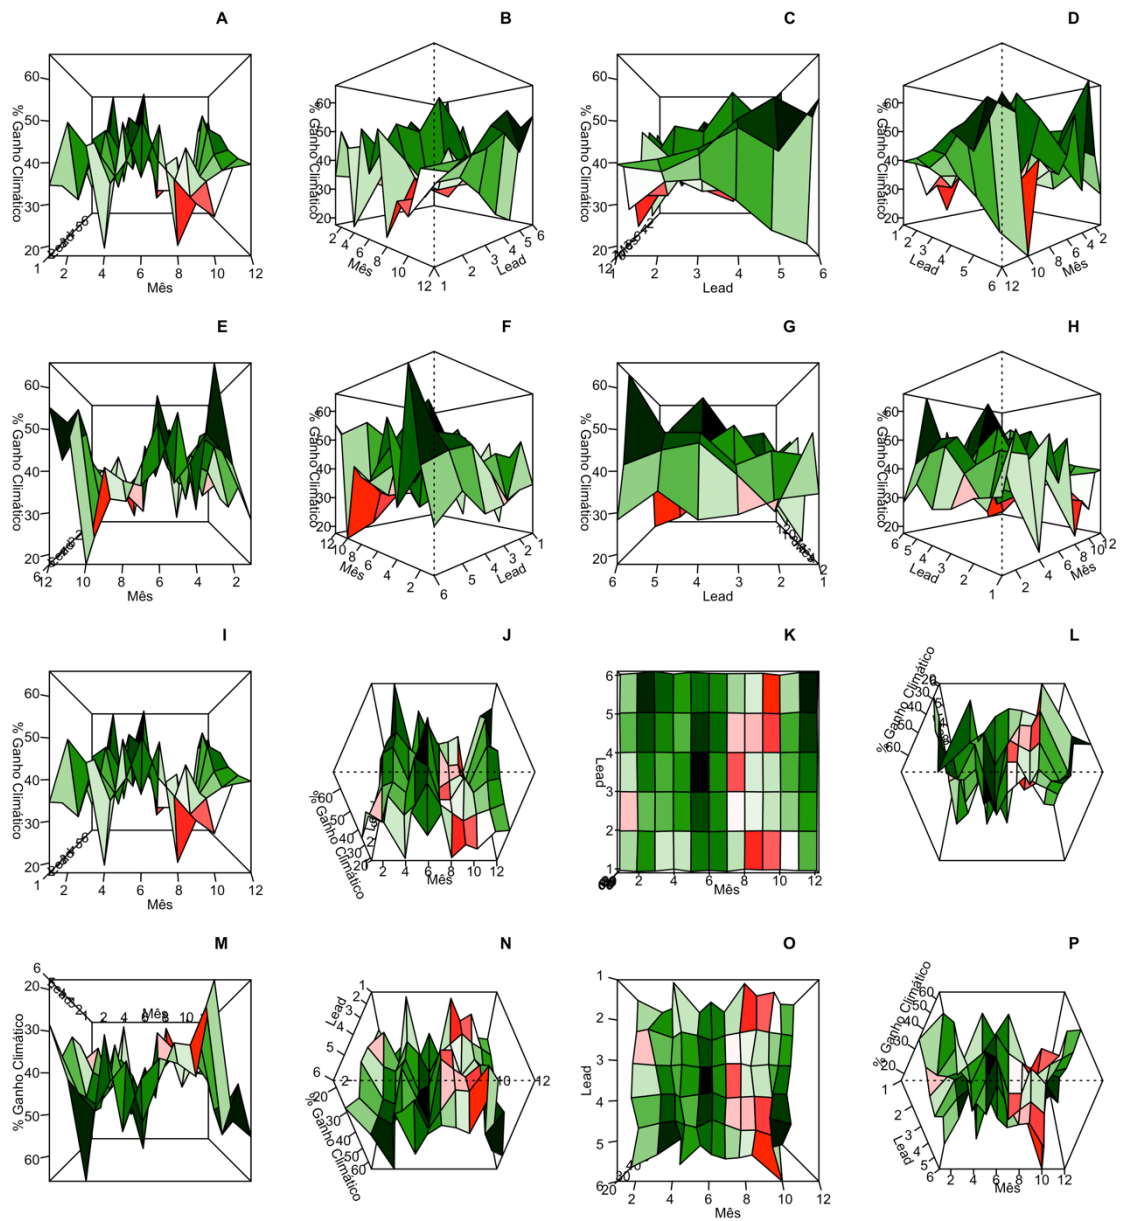


Figura C.1 Plano 3D com o a quantidade de UHEs com ganho climático, pelo NSE, de cada mês e lead

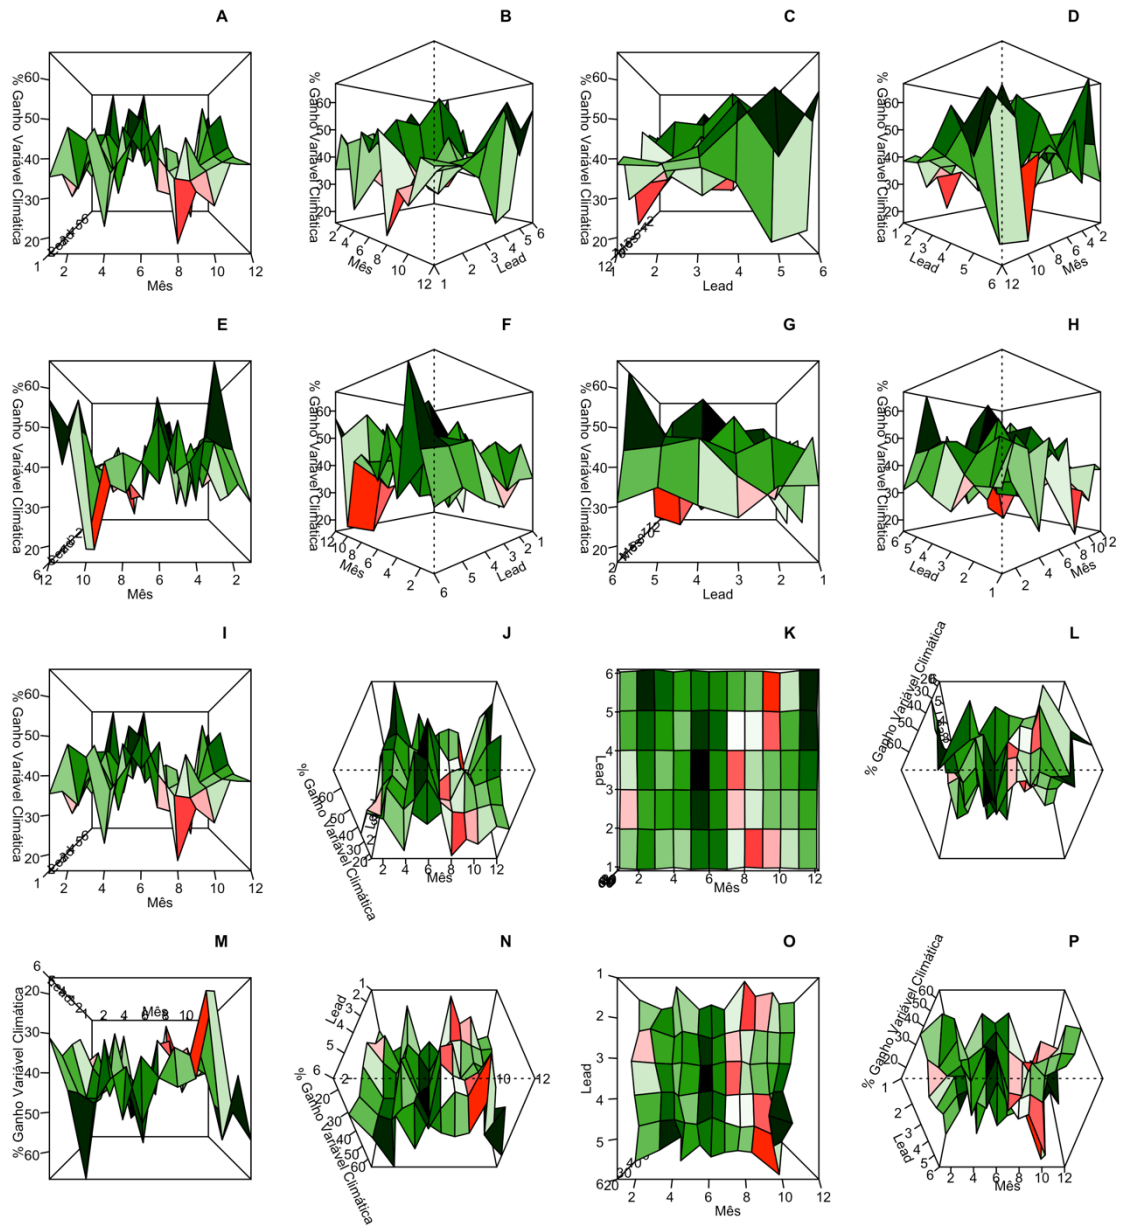


Figura C.2 Plano 3D com o a quantidade de UHEs com ganho climático, pelo KGE, de cada mês e lead

APÊNDICE D – RESULTADOS PELO CONCEITO DE REE

Diferentes métricas para os três modelos propostos
 Agregando todas previsões (REEs e leads) pelos meses

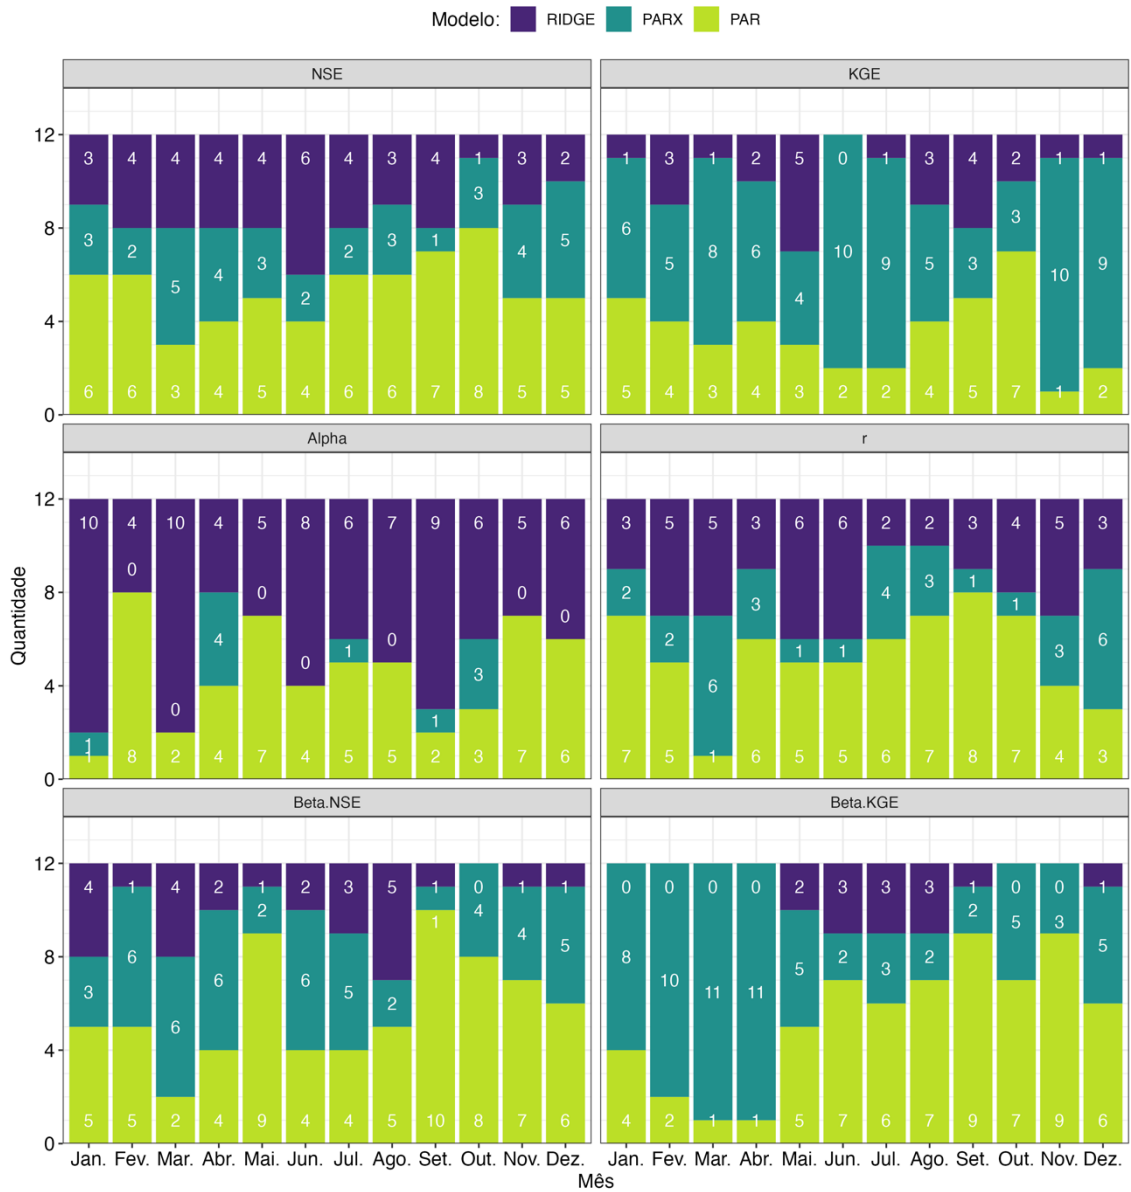


Figura D.1 Ganho de cada modelo para diferentes meses por REE

Diferentes métricas para os três modelos propostos
 Agregando todas previsões (REEs e meses) pelos lead




Figura D.2 Ganho de cada modelo para diferentes horizontes de previsão (*lead*) por REE

Ganho de utilizar modelos climáticos por mês e horizonte de previsão

Agrupados por REE, avaliados pelo NSE




Figura D.3 Valor do NSE para cada mês e horizonte de previsão (*lead*) por REE

APÊNDICE E – RESULTADOS PELO CONCEITO DE SUBSISTEMAS

Diferentes métricas para os três modelos propostos
 Agregando todas previsões (Subsistemas e leads) pelos meses




Figura E.1 Ganho de cada modelo para diferentes meses por subsistema

Diferentes métricas para os três modelos propostos
 Agregando todas previsões (Subsistemas e meses) pelos lead

Modelo: ■ RIDGE ■ PARX ■ PAR




Figura E.2 Ganho de cada modelo para diferentes horizontes de previsão (*lead*) por subsistema