



UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

FRANCISCA LANAI RIBEIRO TORRES

**PREVISÃO DE PREÇOS E VARIÁVEIS  
HIDROLÓGICAS NO MERCADO LIVRE DE  
ENERGIA BRASILEIRO: UMA ABORDAGEM  
BASEADA EM *MACHINE LEARNING* E MÉTODOS  
BAYESIANOS**

Itajubá, 24 de junho de 2024



UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

FRANCISCA LANAI RIBEIRO TORRES

**PREVISÃO DE PREÇOS E VARIÁVEIS  
HIDROLÓGICAS NO MERCADO LIVRE DE  
ENERGIA BRASILEIRO: UMA ABORDAGEM  
BASEADA EM *MACHINE LEARNING* E MÉTODOS  
BAYESIANOS**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para obtenção do título de **Doutora em Ciências em Engenharia Elétrica**.

**Área de Concentração:** Sistemas Elétricos de Potência/Economia do Setor Eletro-Energético

**Orientador:** Prof. Dr. José Wanderley Marangon Lima.

**Coorientadora:** Prof. Dr. Michelle Simões Reboita.

Itajubá, 24 de junho de 2024



UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

FRANCISCA LANAI RIBEIRO TORRES

**PREVISÃO DE PREÇOS E VARIÁVEIS HIDROLÓGICAS NO MERCADO  
LIVRE DE ENERGIA BRASILEIRO: UMA ABORDAGEM BASEADA EM  
MACHINE LEARNING E MÉTODOS BAYESIANOS**

**BANCA EXAMINADORA**

**Prof. Ph.D. Anderson Rodrigo de Queiroz**  
North Carolina State University, NCSC

**Prof<sup>a</sup>. Dr<sup>a</sup>. Anita Rodrigues de Moraes Drumond**  
Universidade de São Paulo, USP

**Prof. Dr. Dorel Soares Ramos**  
Universidade de São Paulo, USP

**Prof. Dr. Benedito Cláudio da Silva**  
Universidade Federal de Itajubá, UNIFEI

**Prof. Dr. Eduardo Crestana Guardia**  
Universidade Federal de Itajubá, UNIFEI

**Prof<sup>a</sup>. Dr<sup>a</sup>. Michelle Simões Reboita**  
Universidade Federal de Itajubá, UNIFEI | Coorientadora

**Prof. Dr. José Wanderley Marangon Lima**  
Universidade Federal de Itajubá, UNIFEI | Orientador

Itajubá, 24 de junho de 2024

# DEDICATÓRIA

DEDICO ESTA TESE A MINHA  
AMADA MÃE, MARIA.

---

---

## AGRADECIMENTO

Primeiramente, expresso minha profunda gratidão a Deus, que me guiou e protegeu durante os anos longe de minha família, proporcionando tranquilidade e sabedoria nos momentos mais desafiadores e me concedendo o inestimável privilégio da vida.

Um sincero agradecimento ao professor José Wanderley Marangon Lima, que me orientou com dedicação e sabedoria durante minha jornada como mestranda e doutoranda no programa de pós-graduação em engenharia elétrica na Universidade Federal de Itajubá (UNIFEI), contribuindo imensamente para o meu crescimento acadêmico.

Agradeço às professoras Michelle Reboita (UNIFEI) e Luana Marangon (Duke University) e ao professor Anderson Rodrigo de Queiroz (North Carolina State University) pela assistência valiosa na implementação dos modelos matemáticos desta tese e pela criteriosa revisão do trabalho desenvolvido.

Ao professor Rubem Cesar (Universidade Federal do Amazonas), que me encorajou a dar um novo passo em minha vida acadêmica na UNIFEI, e à professora e amiga Verônica Etchebehere, por sua orientação decisiva e apoio na escolha do meu orientador.

Ao CNPq, cujo financiamento foi fundamental para sustentar minha estadia em Itajubá durante esses importantes anos de formação.

Aos meus colegas do GESis e MC&E, Cassia Kuki, Giulia Medeiros e Iago Felício, pelo suporte e companheirismo demonstrados, que foram de grande valor para mim ao longo dos últimos anos.

Ao meu pai Donato e às minhas irmãs Dandara, Brianna e Sophia, pelo constante encorajamento e apoio incondicional em todos os momentos de minha jornada.

Por fim, reservo um agradecimento especial e profundo à minha mãe, Maria de Lourdes, cuja fé inabalável em meu potencial nunca vacilou. Ela foi não apenas minha maior incentivadora, mas também minha fonte constante de inspiração e força. Em cada desafio enfrentado, sua presença se fazia sentir, seja através de palavras encorajadoras ou de gestos silenciosos de apoio. É impossível quantificar o impacto de sua influência em minha vida, tanto pessoal quanto acadêmica. Ela é, sem dúvida, a pessoa mais especial da minha vida, e sua benção é um dos maiores presentes que carrego comigo.

---

## EPÍGRAFE

SE PENSAR É O DESTINO DO SER HUMANO, CONTINUAR  
SONHANDO É O SEU GRANDE DESAFIO. E ISTO, É LÓGICO,  
IMPLICA EM TRAJETÓRIAS COM RISCOS, EM VITÓRIAS, COM  
MUITAS LUTAS, E NÃO POUCOS OBSTÁCULOS PELO  
CAMINHO. APESAR DE TUDO, SEJA OUSADO. LIBERTE SUA  
CRIATIVIDADE. E NUNCA DESISTA DE SEUS SONHOS, POIS  
ELES TRANSFORMARÃO SUA VIDA EM  
UMA GRANDE AVENTURA.

**AUGUSTO CURY**

---

---

## RESUMO

### **PREVISÃO DE PREÇOS E VARIÁVEIS HIDROLÓGICAS NO MERCADO LIVRE DE ENERGIA BRASILEIRO: UMA ABORDAGEM BASEADA EM *MACHINE LEARNING* E MÉTODOS BAYESIANOS**

Francisca Lanai Ribeiro Torres

Itajubá

2024

A matriz elétrica brasileira é caracterizada pela participação majoritária da fonte hidráulica em sua composição. Os agentes que comercializam energia no mercado livre tomam decisões considerando, entre outros fatores, as condições hidrológicas futuras do Sistema Interligado Nacional (SIN), o impacto dessas condições na expectativa de comportamento futuro do Preço de Liquidação das Diferenças (PLD) (preço *spot* da energia), bem como o comportamento dos preços efetivamente negociados no mercado, que é sintetizado pela *Curva Forward* de preços. No curto prazo, os estudos de prospecção de PLD são realizados utilizando as vazões previstas por um modelo do tipo chuva-vazão, que é alimentado com a precipitação gerada por modelos numéricos de previsão de tempo. No médio prazo, a estratégia dos agentes varia. Alguns utilizam cenários baseados em séries históricas de vazão, enquanto outros utilizam os resultados da combinação entre um chuva-vazão com um conjunto de séries históricas de precipitação ou com as previsões de modelos climáticos. Já no caso da *Curva Forward* de preços, o usual é consultar o estado presente da curva, existindo ainda poucos trabalhos voltados para a elaboração de prospectivos dessa série temporal específica.

Diante do exposto e da necessidade de continuar aperfeiçoando o processo de previsão de variáveis importantes para a tomada de decisões comerciais, o objetivo desta tese de doutorado é desenvolver metodologias para previsão de variáveis hidrológicas (vazão e chuva) e do preço formado pelos agentes no mercado livre (*Curva Forward de preços*), bem como contribuir para o

---

---

estreitamento da relação entre os setores acadêmico e empresarial através da proposição de soluções, na forma de produtos, para problemas reais do mercado livre de energia brasileiro.

O primeiro produto proposto é voltado para o curto prazo e consiste em um novo *framework* baseado em *Bayesian Model Averaging* (BMA) para a previsão das vazões afluentes aos aproveitamentos do SIN. BMA é um método estatístico que combina modelos utilizando distribuições de probabilidade *a posteriori*. Previsões de vazão para 11 dias à frente são produzidas ponderando os membros de um *Multi-model Ensemble* (MME) de modelos hidrológicos chuva-vazão. Os pesos são dinâmicos, recalculados periodicamente com dados recentes. A seleção de membros com bom desempenho, utilizando o princípio de *Occam's Razor*, melhora a performance do MME. Testado em 139 aproveitamentos entre 2019 e 2020, o método realizou previsões com performance superior às dos modelos individuais, especialmente nas regiões Sul, Centro-Oeste e Sudeste nos primeiros dias do horizonte de previsão.

O segundo produto foca no médio prazo e aprimora as previsões sazonais de precipitação no Brasil. Ele explora o desenvolvimento de modelos híbridos preditivos usando *Multivariable Linear Regression* (MLR) e *Support Vector Machine* (SVM), considerando preditores baseados em índices climáticos, análise de precipitação do Climate Prediction Center (CPC) e previsões do *Seasonal Forecast System 5* (SEAS5). Validados de janeiro de 2017 a dezembro de 2020, os modelos MLR e SVM geraram previsões com maior acurácia e menor viés que o SEAS5, especialmente no Sudeste, Centro-Oeste e Norte durante o trimestre DJF, com o modelo SVM apresentando melhor desempenho geral.

O terceiro produto, por sua vez, explora a aplicação de redes neurais artificiais para a previsão da *Curva Forward* de preços da energia convencional no mercado livre brasileiro. Foram avaliadas redes Recorrente (RNN), *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU) uni- e bidirecionais, além da clássica *Multi-Layer Perceptron* (MLP), considerando variações na arquitetura e nos preditores exógenos considerados, tais como energia natural afluyente, carga, armazenamento de energia e PLD. Dentre as redes avaliadas, a GRU apresentou melhor desempenho preditivo, enquanto a LSTM se destacou em termos de retorno financeiro acumulado em um experimento no qual um agente comercializador pratica *trading* direcional.

**Palavras-Chave:** *Multi-model Ensemble*, *Bayesian Model Averaging*, Previsão de Vazão, Previsão Sazonal de Precipitação, Padrões de Teleconexões, *Machine Learning*, *Artificial Neural Networks*, Previsão de Preços.

---

# ABSTRACT

## FORECASTING PRICES AND HYDROLOGICAL VARIABLES IN THE BRAZILIAN FREE ENERGY MARKET: A MACHINE LEARNING AND BAYESIAN APPROACH

Francisca Lanai Ribeiro Torres

Itajubá

2024

The Brazilian electricity mix is characterized by a high share of hydropower generation. Agents trading energy in the free market make decisions by considering, among other factors, the future hydrological conditions of the National Interconnected System (SIN), the impact of these conditions on the predictions of the Settlement Price of Differences (PLD) (spot price of energy), and the behavior of prices negotiated in the market, the last summarized by the Forward Price Curve. In the short-term, PLD prospecting studies rely on streamflow rates predicted by a rainfall-runoff model, which uses as input the precipitation data generated by numerical weather forecasting models. In the medium term, agents adopt varying strategies. Some rely on scenarios derived from historical streamflow timeseries, while others integrate a rainfall-runoff model with historical precipitation data or seasonal precipitation forecasts. Regarding the Forward Price Curve, it is typical to consider only its present state, with limited research dedicated to forecast this particular time series.

In light of this context and the ongoing need to refine the forecasting of key variables for commercial decision-making, this research aims to develop methodologies to forecast hydrological variables (streamflow and rainfall) and the price established by agents in the Brazilian energy free market (Forward Price Curve). Additionally, this research aims to strengthen the relationship between the academic and business sectors by proposing practical solutions (in the form of products) to real problems of the energy market.

The first product focuses on the short-term and introduces a new framework based on Bayesian Model Averaging (BMA) to forecast natural inflows to reservoirs and hydropower plants

---

in the Brazilian hydropower system. BMA is a statistical method that combines models using posterior probability distributions. Streamflow forecasts for 11 days ahead are produced by assigning weights to the members of a Multi-model Ensemble (MME) of rainfall-runoff hydrological models. The weights are dynamic, periodically recalculated with recent data. Selecting high-performing members, using Occam's Razor principle, improves the MME's performance. Tested on 139 reservoirs between 2019 and 2020, the method showed superior forecasts compared to individual models, especially in the South, Midwest, and Southeast regions in the early days of the forecast horizon.

Focused on the medium-term case, the second product of this research aims to refine seasonal precipitation forecasts for Brazil by developing predictive hybrid precipitation models using Multivariable Linear Regression (MLR) and Support Vector Machine (SVM). The approach incorporates climate indices related to different teleconnection patterns that affect Brazil precipitation, the Climate Prediction Center (CPC) unified gauge-based global daily precipitation analysis, and precipitation forecasts from Seasonal Forecast System 5 (SEAS5) as predictors. Validated from January 2017 to December 2020, the MLR and SVM models showed greater accuracy and lower bias than SEAS5, especially in the Southeast, Midwest, and North regions during the DJF quarter, with the SVM model demonstrating the best overall performance.

The third product introduces a methodology centered around Artificial Neural Networks (ANNs) to forecast the Forward Price Curve of conventional energy in the Brazilian energy free market. This study evaluates Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Recurrent (RNN) neural networks, both uni- and bidirectional, alongside the traditional Multi-Layer Perceptron (MLP). It also considers structural variations in ANN architectures and the impact of exogenous predictors related to the SIN and the Brazilian energy free market, including natural inflow energy, load, reservoir storage levels, and the energy spot price. Among the neural networks evaluated, the GRU demonstrated superior predictive performance, while the LSTM excelled with regard to accumulated financial return in an experiment where a trading agent performed directional trading informed by neural network predictions.

**Keywords:** Multi-model Ensemble, Bayesian Model Averaging, Streamflow Forecasting, Seasonal Precipitation Forecasting, Teleconnection Patterns, Machine Learning, Artificial Neural Networks, Price Forecasting.

---

## LISTA DE FIGURAS

- Figura 1 - Principais reservatórios e hidrelétricas do SIN por subsistema (Sul, Centro-Oeste/Sudeste, Nordeste e Norte). No mapa, a vazão Média de Longo Termo (MLT) anual [ $m^3/s$ ] é utilizada para destacar os aproveitamentos de acordo as vazões médias entre 1931 e 2020.....35
- Figura 2 - Cadeias chuva-vazão compostas pela combinação dos modelos GFS, GEFS, ETA e ENS com o SMAP/ONS, o MGB e as ANNs.....41
- Figura 3 - Fluxograma do procedimento adotado para o cálculo da BMA. ....44
- Figura 4 - Exemplo da aplicação dos pesos às previsões feitas em uma quinta-feira. ....45
- Figura 5 - Fluxograma do procedimento adotado para o cálculo da BMA via *backtest*. ....45
- Figura 6 - Segregação das previsões feitas por uma cadeia chuva-vazão de acordo com os dias do horizonte temporal de previsão (dia[1], dia[2], ..., dia[11]). Na imagem, é exemplificado como os resultados das execuções (realizadas de 2019-10-01 a 2019-10-10 no exemplo) geram 11 grupos de dados. ....46
- Figura 7 - Vazões previstas pelas cadeias chuva-vazão e pesos aplicados para a formação da BMA associada às vazões afluentes da hidrelétrica Água Vermelha. A primeira imagem mostra os membros do *ensemble* (GFS-MGB, ETA-MGB, GEFS-MGB, inf(GEFS-MGB), median(GEFS-MGB), sup(GEFS-MGB), ANN, SMAP/ONS), o cenário determinístico de vazões computado via BMA e as vazões observadas *in situ* (QObs) para o período de agosto de 2019 a setembro de 2020. A DM calculada com as previsões da BMA é de 0,084, inferior às DMs calculadas com as previsões das outras cadeias chuva-vazão. ....49
- Figura 8 - Boxplot dos MAPEs, NSEs e DMs calculados para as vazões afluentes aos reservatórios e hidrelétricas do SIN (contemplados pelo modelo SMAP/ONS) utilizando as previsões feitas com 1, 7 e 11 dias de antecedência. Na composição dos gráficos, foram utilizados os dados obtidos com as execuções retroativas durante o período de *backtest*. Ao todo, foram avaliadas as previsões de vazão realizadas para 67 aproveitamentos. Os boxplots das imagens apresentam as distribuições dos MAPEs, NSEs e DMs em quartis para cada uma das cadeias chuva-vazão. A linha horizontal no interior de cada caixa representa a mediana, enquanto as linhas delimitadoras inferior e superior representam os quartis  $Q1$  e  $Q3$ , respectivamente. O limite superior do boxplot é definido por  $Q3 + 1,5(Q3 - Q1)$  e o inferior por  $Q3 - 1,5(Q3 - Q1)$ . Os pontos fora das caixas representam os *outliers*, enquanto o marcador em preto representa a média. A escala do eixo y de cada gráfico passou por um processo de transformação usando a função raiz cúbica  $3y$  para a melhor visualização dos resultados.....52
- Figura 9 - Boxplot dos MAPEs, NSEs e DMs calculados para as vazões afluentes aos reservatórios e hidrelétricas do SIN (não contemplados pelo modelo SMAP/ONS) utilizando as previsões feitas com 1, 7 e 11 dias de antecedência. Na composição dos gráficos, foram utilizados os dados obtidos com as execuções retroativas durante o período de *backtest*. Ao todo, foram avaliadas as previsões de vazão realizadas para 72 aproveitamentos. A escala do eixo y de cada gráfico passou por um processo de transformação usando a função raiz cúbica  $3y$  para a melhor visualização dos resultados. ....54

Figura 10 - Padrão espacial de MAPEs, NSEs e DMs das previsões de vazão feitas pela BMA para os dias 1, 7 e 11. Nos mapas, a vazão média de longo termo é utilizada para definir o tamanho do círculo que destaca os reservatórios e hidrelétricas.....56

Figura 11 - Padrão espacial de  $1 - FDADMTcalc$  calculado através da aplicação do Teste de Hipóteses de Diebold-Mariano considerando todas as previsões realizadas até 11 dias à frente. Cada mapa apresenta os resultados da comparação entre as previsões feitas por um dos membros do *ensemble* e a BMA. Se  $0 \leq 1 - FDADMTcalc < 0.05$ , onde  $1 - FDADMTcalc$  é igual ao *p-value* do teste em (12) dado  $\alpha = 0,05$ , a série temporal de previsões realizadas pela BMA é significativamente mais acurada que a série associada ao membro concorrente; se  $0.05 \leq 1 - FDA(DMTcalc) \leq 0.95$ , nenhuma das séries temporais é significativamente mais acurada que outra; e se  $0.95 < 1 - FDA(DMTcalc) \leq 1$ , onde  $FDADMTcalc$  é igual ao *p-value* do teste em (11) dado  $\alpha = 0,05$ , a série temporal de previsões feitas pelo membro do *ensemble* é significativamente mais acurada que a série computada pela BMA. ....57

Figura 12 - Boxplot dos pesos calculados para os reservatórios e hidrelétricas do SIN por cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um marcador negro junto ao seu valor numérico.....58

Figura 13 - Boxplots dos pesos calculados para os reservatórios e hidrelétricas do SIN (com vazões simuladas pelo SMAP/ONS) ao longo do tempo. Em cada imagem é apresentada a evolução temporal dos boxplots de pesos computados para todos os postos fluviométricos e cada cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um ponto negro.....59

Figura 14 - Boxplots dos pesos calculados para os reservatórios e hidrelétricas do SIN (com vazões não simuladas pelo SMAP/ONS) ao longo do tempo. Em cada imagem é apresentada a evolução temporal dos boxplots de pesos computados para todos os postos fluviométricos e cada cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um marcador negro.....60

Figura 15 - Precipitação média anual nas regiões do Brasil obtida a partir dos dados do *Gauge-Based Analysis of Global Daily Precipitation* [139] no período de jan-1993 a dez-2016. O Brasil está limitado por um polígono com borda mais espessa na cor preta e os acrônimos N, CO, NE, SE e S indicam, respectivamente, região Norte, Centro-Oeste, Nordeste, Sudeste e Sul. ....70

Figura 16 - *Inputs* dos modelos MLR e SVM. (a.) exemplifica como os dados da série temporal de um índice climático são utilizados para previsão sazonal de anomalia de precipitação (e.g., a previsão realizada em jan-2016 para o período de jan-2016 a jul-2016 utiliza os últimos 7 meses da série temporal do índice). (b.) detalha a aplicação das anomalias de precipitação do SEAS5 (e.g., a previsão realizada em jan-2016 para o período jan-2016 a jul-2016 utiliza os dados das execuções do SEAS5 que foram inicializadas em jan-2016). (c.) indica como as anomalias de precipitação do CPC são empregadas (e.g., a previsão realizada em jan-2016 para o período jan-2016 a jul-2016 usa dados históricos dos últimos 12 meses).....75

Figura 17 - Diagramas de regressão SVM. Em (a.) ilustra-se os conceitos básicos por trás da metodologia SVM (ou seja, vetores de suporte, hiperplano ótimo e margem de erro). (b.) e (c.) exemplificam o uso de funções de *kernel* para remapear os dados  $x_i$  de um espaço de baixa para um de alta dimensão  $\Phi(x_i)$  onde o processo de regressão pode ser realizado com maior facilidade. ....79

- 
- Figura 18 - Modelos estatísticos de previsão sazonal de precipitação. A imagem apresenta o conjunto de *inputs* e *outputs* dos modelos estatísticos implementados (MLR e SVM) para cada célula de uma grade sobre a região de interesse e por trimestre (MAM, JJA, SON e DJF). .....83
- Figura 19 - Segregação das previsões sazonais de precipitação de acordo com o mês do horizonte temporal de previsão ( $n = 1, 2, \dots, 7$ ) e os trimestres MAM, JJA, SON e DJF. Na imagem é apresentado, como exemplo ilustrativo, o procedimento de segregação por estação anual das previsões do conjunto em que  $n = 5$ . .....84
- Figura 20 - MAE [mm/mês] das previsões sazonais de precipitação realizadas pelo SEAS5 nos trimestres DJF. Nessa avaliação, os dados de precipitação total do *hindcast* (jan-1993 a dez-2016) foram acumulados mensalmente e segregados por mês do horizonte temporal de previsão (meses 1, 3 e 7), respectivamente. ....86
- Figura 21 - *Bias* [mm/mês] das previsões sazonais de precipitação realizadas pelo SEAS5 no trimestre DJF. Nessa avaliação, os dados de precipitação total do *hindcast* (jan-1993 a dez-2016) foram acumulados mensalmente e segregados por mês do horizonte temporal de previsão (meses 1, 3 e 7), respectivamente. ....87
- Figura 22 - MAE [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para o trimestre DJF. Os resultados da simulação de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7) e o trimestre DJF. ....89
- Figura 23 - Boxplots gerados com os MAEs [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para todas as células de uma grade sobre as regiões S, SE, N, NE e CO no trimestre DJF. Os resultados da simulação de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7).91
- Figura 24 - *Bias* [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para o trimestre DJF. Os resultados das execuções de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7) e o trimestre DJF. ....92
- Figura 25 - Boxplots gerados com os *biases* [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos estatísticos (MLR e SVM) e pelo SEAS5 para todos os pontos de grade da região estudada no trimestre DJF. Os resultados das execuções de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7).93
- Figura 26 - Séries temporais das previsões de precipitação feitas pelos modelos MLR, SVM e SEAS5 (para o mês  $n = 1$  do horizonte temporal de previsão) de jan-2017 até dez-2020. Os dados foram computados para cada região do Brasil por meio do cálculo da média da precipitação associada às células internas a cada região.....94
- Figura 27 - Padrão espacial dos resultados obtidos por meio do Teste de Hipóteses de Diebold-Mariano, considerando um nível de significância  $\alpha$  de 0,05, um horizonte de previsão de sete meses à frente e as previsões mensais feitas de janeiro de 2017 a dezembro de 2020. O conjunto de mapas mostra, em cores, os setores do Brasil para os quais as previsões realizadas por um modelo específico são significativamente mais precisas do que as feitas pelo modelo concorrente. ....95
-

---

Figura 28 - Visão geral do <i>framework</i> proposto para a previsão dos preços da energia no Mercado Livre Brasileiro.....	111
Figura 29 - As séries temporais consideradas no <i>framework</i> de previsão de preços incluem: (a.) os valores máximo e mínimo, bem como a média e a mediana do preço da energia convencional a ser gerada no mês seguinte (apenas mês 1 do horizonte da Curva Forward de preços); (b.) a amplitude e o desvio padrão dos preços negociados para a energia convencional; (c.) o Preço de Liquidação das Diferenças do Submercado Sudeste; (d.) a carga total do Submercado Sudeste; (e.) a energia armazenada no Submercado Sudeste/Centro-Oeste; e (f.) a energia natural afluente aos submercados Sudeste/Centro-Oeste, Sul, Nordeste e Norte.....	124
Figura 30 - Curvas das métricas de erro MAE, MAPE, Bias e RMSE considerando diferentes configurações para a rede GRU, isto é, variando o número de camadas e neurônios, assim como as combinações de preditores utilizados.....	129
Figura 31 - Previsões do Preço EC realizadas pela rede GRU, considerando um horizonte de 6 meses à frente. ....	131
Figura 32 - Curvas da métrica MAE calculada considerando diferentes configurações de redes GRU, variando a combinação de preditores bem como as <i>lags</i> consideradas. ....	132
Figura 33 - Retorno financeiro acumulado ao longo do horizonte temporal de teste. ....	139
Figura 34 - O gráfico (a.) apresenta o retorno financeiro diário acumulado quando o agente comercializador toma decisões com base no preço previsto pelas redes LSTM e BRNN, bem como quando a operação no mercado de energia é “perfeita”. Já em (b.), é feita uma comparação entre os histogramas de retorno financeiro diário considerando os preços previstos pelas redes LSTM, BRNN e pela estratégia <i>Momentum-Based</i> . ....	140
Figura 35 - Curvas das métricas MSE, NSE, d e r considerando diferentes configurações de redes GRU, variando o número de camadas e neurônios, assim como as combinações de preditores utilizados.....	144

---

---

## LISTA DE TABELAS

Tabela 1 - Modelos Numéricos de Previsão de Tempo.....	37
Tabela 2 - Métricas de avaliação e testes de hipóteses.....	46
Tabela 3 - Índices climáticos de teleconexão e suas fontes de dados.....	72
Tabela 4 - <i>Ranking</i> dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre DJF).....	81
Tabela 5 - Métricas de avaliação e teste de hipóteses. ....	84
Tabela 6 - Sumário da média das métricas MAE [mm/mês] e <i>bias</i> [mm/mês] calculadas com a precipitação do SEAS5 (jan-1993 a dez-2016) para o trimestre DJF por região e mês do horizonte temporal de previsão.....	88
Tabela 7 - <i>Ranking</i> dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre MAM).....	98
Tabela 8 - <i>Ranking</i> dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre JJA).....	98
Tabela 9 - <i>Ranking</i> dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre SON).....	99
Tabela 10 - Métricas de avaliação de desempenho. ....	119
Tabela 11 - Teste de hipóteses para comparação par a par das previsões. ....	121
Tabela 12 - Resultados da avaliação dos modelos usando métricas de erro, eficiência e correlação. ....	127
Tabela 13 - Resultados da avaliação dos modelos usando o Teste de Hipóteses de Diebold-Mariano.....	133
Tabela 14 - Retorno financeiro e acurácia da previsão de movimentos de preço. ....	138

---

---

## LISTA DE ABREVIATURAS E SIGLAS

ACL	AMBIENTE DE CONTRATAÇÃO LIVRE
ACR	AMBIENTE DE CONTRATAÇÃO REGULADO
ANN	ARTIFICIAL NEURAL NETWORK
BBCE	BALCÃO BRASILEIRO DE COMERCIALIZAÇÃO DE ENERGIA
BGRU	BIDIRECTIONAL GATED RECURRENT UNIT NEURAL NETWORK
BLSTM	BIDIRECTIONAL LONG SHORT-TERM MEMORY NEURAL NETWORK
BMA	BAYESIAN MODEL AVERAGING
BRNN	BIDIRECTIONAL RECURRENT NEURAL NETWORK
CCEAL	CONTRATO DE COMERCIALIZAÇÃO DE ENERGIA NO AMBIENTE LIVRE
CCEAR	CONTRATO DE COMERCIALIZAÇÃO DE ENERGIA NO AMBIENTE REGULADO
CCEE	CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA
CO	CENTRO-OESTE
CPC	CLIMATE PREDICTION CENTER
CPTEC	CENTRO DE PREVISÃO DE TEMPO E ESTUDOS CLIMÁTICOS
CRH	CLASSE DE RESPOSTA HIDROLÓGICA
d	ÍNDICE DE WILLMOTT
DJF	DEZEMBRO, JANEIRO E FEVEREIRO
EARM	ENERGIA ARMazenada
EC	ENERGIA CONVENCIONAL
ECMWF	EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS
ECQ	ENERGIA DE COGERAÇÃO QUALIFICADA
EI	ENERGIA INCENTIVADA
EM	EXPECTATIVA-MAXIMIZAÇÃO
ENA	ENERGIA NATURAL AFLUENTE
ENN	ENSEMBLE NEURAL NETWORK
ENSO	EL NINO – SOUTH OSCILLATION

---

---

ETA	ETA MODEL
FOREX	FOREIGN EXCHANGE MARKET
GEFS	GLOBAL ENSEMBLE FORECAST SYSTEM
GFS	GLOBAL FORECAST SYSTEM
GRU	GATED RECURRENT UNIT
IPH	INSTITUTO DE PESQUISAS HIDRÁULICAS
JJA	JUNHO, JULHO E AGOSTO
LSTM	LONG SHORT-TERM MEMORY NEURAL NETWORK
MAE	MEAN ABSOLUTE ERROR
MAM	MARÇO, ABRIL E MAIO
MAPE	MEAN ABSOLUTE PERCENTAGE ERROR
MCP	MERCADO DE CURTO PRAZO
MCMC	MARKOV CHAIN MONTE CARLO
MEL	MODELAGEM ESTOCÁSTICA LINEAR
MGB	MODELO DE GRANDES BACIAS
MLE	MAXIMUM LIKELIHOOD ESTIMATION
MLR	MULTIVARIABLE LINEAR REGRESSION
MLT	MÉDIA DE LONGO TERMO
MME	MULTI-MODEL ENSEMBLE
MSE	MEAN SQUARED ERROR
N	NORTE
NCEP	NATIONAL CENTERS FOR ENVIRONMENTAL PREDICTION
NE	NORDESTE
NSE	NASH-SUTCLIFFE EFFICIENCY COEFFICIENT
ONS	OPERADOR NACIONAL DO SISTEMA ELÉTRICO
PREÇO EC	PREÇO DA ENERGIA CONVENCIONAL
PLD	PREÇO DA LIQUIDAÇÃO DAS DIFERENÇAS
QOBS	ARQUIVO DE VAZÕES OBSERVADAS
r	COEFICIENTE DE CORRELAÇÃO DE PEARSON

---

RMSE	ROOT MEAN SQUARED ERROR
RNN	RECURRENT NEURAL NETWORK
S	SUL
SE	SUDESTE
SEAS5	SEASONAL FORECAST SYSTEM 5
SIN	SISTEMA INTERCONECTADO NACIONAL
SMAP	SOIL MOISTURE ACCOUNTING PROCEDURE
SON	SETEMBRO, OUTUBRO E NOVEMBRO
SVM	SUPPORT VECTOR MACHINE
TSM	TEMPERATURA DA SUPERFÍCIE DO MAR
URH	UNIDADE DE RESPOSTA HIDROLÓGICA
ZCAS	ZONA DE CONVERGÊNCIA DO ATLÂNTICO SUL

---

---

## LISTA DE SÍMBOLOS

### SÍMBOLOS DO CAPÍTULO 2

$t$	TEMPO $(1, 2, \dots, T)$
$m$	MODELO $(1, 2, \dots, M)$
$h$	HORIZONTE TEMPORAL DE PREVISÃO
$i$	NEURÔNIO DE UMA REDE NEURAL ARTIFICIAL $(1, 2, \dots, N)$
$Y$	VARIÁVEL PREDITA
$y_t$	VALOR OBSERVADO PARA A VARIÁVEL PREDITA NO TEMPO $t$
$\bar{y}$	MÉDIA DOS VALORES OBSERVADOS PARA A VARIÁVEL PREDITA
$x_m$	CONJUNTO DE PREVISÕES FEITAS PELO MODELO $m$
$x_{m,t}$	PREVISÃO FEITA PELO MODELO $m$ NO TEMPO $t$
$w_m$	PESO APLICADO ÀS PREVISÕES DO MODELO $m$
$\sigma_m^2$	VARIÂNCIA DO MODELO $m$
$\hat{z}_{m,t}$	VARIÁVEL LATENTE CALCULADA PARA O MODELO $m$ NO TEMPO $t$
$u_i$	INPUT DO NEURÔNIO ARTIFICIAL $i$
$s_i$	PESO APLICADO A $u_i$
$f(\cdot)$	FUNÇÃO DE ATIVAÇÃO
$l(\cdot)$	LOG-LIKELIHOOD
$g(\cdot)$	FUNÇÃO GAUSSIANA
$loss(\cdot)$	FUNÇÃO DE PERDA
$d(\cdot)$	FUNÇÃO DIFERENCIAL DE PERDA
$E(\cdot)$	ESPERANÇA MATEMÁTICA
$\alpha$	NÍVEL DE SIGNIFICÂNCIA ADOTADO EM UM TESTE DE HIPÓTESES
$FDA(\cdot)$	FUNÇÃO DENSIDADE DE PROBABILIDADE ACUMULADA
$\bar{d}$	MÉDIA DA FUNÇÃO DIFERENCIAL DE PERDA
$H_0$	HIPÓTESE NULA

---

---

$H_a$	HIPÓTESE ALTERNATIVA
$\theta$	PARÂMETROS $\{w_m, \sigma_m, m = 1, 2, 3, \dots, M\}$ DA FUNÇÃO $l(\cdot)$
$\mathcal{H}$	CONJUNTO DE MODELOS SELECIONADOS UTILIZANDO O PRINCÍPIO DE OCCAM'S RAZOR
$C$	CONSTANTE

### SÍMBOLOS DO CAPÍTULO 3

$t$	TEMPO $(1, 2, \dots, T)$
$l$	ÍNDICE DOS PREDITORES $(1, 2, \dots, n)$
$x_l(t)$	PREDITOR
$y(t)$	PREDITANTE
$\varepsilon(t)$	RESÍDUO
$\beta_0$	COEFICIENTE LINEAR
$\beta_l$	COEFICIENTE ANGULAR ASSOCIADO AO PREDITOR $i$
$w$	VETOR PERPENDICULAR AO HIPERPLANO ÓTIMO DE UMA SVM
$\xi$ e $\xi^*$	VARIÁVEIS DE FOLGA
$b$	CONSTANTE
$c$	CONSTANTE
$\beta$	CONSTANTE
$p$	GRAU DE UM POLINÔMIO
$\alpha$	VARIÁVEL DUAL
$\phi(\cdot)$	FUNÇÃO DE TRANSFORMAÇÃO
$K(\cdot)$	FUNÇÃO <i>KERNEL</i>

### SÍMBOLOS DO CAPÍTULO 4

$t$	TEMPO $(1, 2, \dots, T)$
$h$	ESTADO OCULTO
$x$	DADOS DE ENTRADA

---

---

$w$	PESO APLICADO A ENTRADA $x$
$b$	VIÉS
$f(\cdot)$	FUNÇÃO DE ATIVAÇÃO
$\sigma(\cdot)$	FUNÇÃO DE ATIVAÇÃO SIGMOIDAL
$\tanh(\cdot)$	FUNÇÃO DE ATIVAÇÃO TANGENTE HIPERBÓLICA
$f$	FORGET GATE
$i$	INPUT GATE
$o$	OUTPUT GATE
$z$	UPDATE GATE
$r$	RESET GATE
$C$	ESTADO DA CÉLULA
$\tilde{C}$	CANDIDATO A ESTADO DA CÉLULA
$\tilde{h}$	CANDIDATO A ESTADO OCULTO
$\vec{h}$	ESTADO OCULTO DO TIPO FORWARD
$\overleftarrow{h}$	ESTADO OCULTO DO TIPO BACKWARD
$y$	VALORES OBSERVADOS
$\bar{y}$	MÉDIA DOS VALORES OBSERVADOS
$\hat{y}$	PREVISÕES
$\bar{\hat{y}}$	MÉDIA DAS PREVISÕES
$E(\cdot)$	ESPERANÇA MATEMÁTICA
$\alpha$	NÍVEL DE SIGNIFICÂNCIA ADOTADO EM UM TESTE DE HIPÓTESES
$FDA(\cdot)$	FUNÇÃO DENSIDADE DE PROBABILIDADE ACUMULADA
$\bar{d}$	MÉDIA DA FUNÇÃO DIFERENCIAL DE PERDA
$H_0$	HIPÓTESE NULA
$H_a$	HIPÓTESE ALTERNATIVA
$RF$	RETORNO FINANCEIRO
$RF_D$	RETORNO FINANCEIRO DIÁRIO
$Preço_d$	PREÇO DA ENERGIA CONVENCIONAL NO DIA $d$

---

---

# SUMÁRIO

<b>RESUMO.....</b>	<b>4</b>
<b>ABSTRACT.....</b>	<b>6</b>
<b>LISTA DE FIGURAS .....</b>	<b>8</b>
<b>LISTA DE TABELAS.....</b>	<b>12</b>
<b>LISTA DE ABREVIATURAS E SIGLAS .....</b>	<b>13</b>
<b>LISTA DE SÍMBOLOS.....</b>	<b>16</b>
<b>CAPÍTULO 1 .....</b>	<b>22</b>
<b>1.1. DEFINIÇÃO DO PROBLEMA.....</b>	<b>22</b>
1.1.1. CONTEXTO DA PESQUISA.....	22
1.1.2. QUALIFICAÇÃO DO PROBLEMA ABORDADO .....	24
<b>1.2. OBJETIVOS .....</b>	<b>26</b>
1.2.1. OBJETIVO GERAL.....	26
1.2.2. OBJETIVOS ESPECÍFICOS .....	26
<b>1.3. ESTRUTURA DA TESE .....</b>	<b>27</b>
<b>CAPÍTULO 2 .....</b>	<b>29</b>
<b>2.1. RESUMO .....</b>	<b>29</b>
<b>2.2. CONTEXTUALIZAÇÃO.....</b>	<b>30</b>
2.2.1. ESTUDOS RELACIONADOS .....	32
2.2.2. PROPÓSITO DA PESQUISA .....	34
2.2.3. ESTRUTURA DO CAPÍTULO .....	34
<b>2.3. METODOLOGIA .....</b>	<b>35</b>
2.3.1. ÁREA DE ESTUDO .....	35
2.3.2. DADOS .....	36
2.3.3. MODELOS CHUVA-VAZÃO SIMULADOS.....	38
2.3.4. CADEIAS CHUVA-VAZÃO .....	40
2.3.5. PONDERAÇÃO BAYESIANA DE MODELOS APLICADA À PREVISÃO DE VAZÕES.....	41
<b>2.4. RESULTADOS E DISCUSSÃO .....</b>	<b>48</b>
2.4.1. PERFORMANCE GERAL DO <i>ENSEMBLE</i> .....	48
2.4.2. PERFORMANCE ESPACIAL DA BMA.....	55
2.4.3. PESOS APLICADOS AOS MEMBROS DO ENSEMBLE.....	58
<b>2.5. CONCLUSÃO .....</b>	<b>61</b>

---

---

<b>CAPÍTULO 3</b> .....	<b>63</b>
<b>3.1. RESUMO</b> .....	<b>63</b>
<b>3.2. CONTEXTUALIZAÇÃO</b> .....	<b>63</b>
3.2.1. ESTUDOS RELACIONADOS .....	65
3.2.2. PROPÓSITO DA PESQUISA .....	68
3.2.3. ESTRUTURA DO CAPÍTULO .....	69
<b>3.3. METODOLOGIA</b> .....	<b>70</b>
3.3.1. ÁREA DE ESTUDO .....	70
3.3.2. DADOS .....	71
3.3.3. MODELOS ESTATÍSTICOS .....	74
<b>3.4. RESULTADOS E DISCUSSÃO</b> .....	<b>85</b>
3.4.1. SEAS5 <i>HINDCAST</i> (jan-1993 a dez-2016).....	85
3.4.2. PERFORMANCE DOS MODELOS MLR E SVM NO TRIMESTRE DJF (jan-2017 a dez-2020).....	88
3.4.3. PERFORMANCE GERAL DOS MODELOS MLR E SVM (jan-2017 a dez-2020)	93
<b>3.5. CONCLUSÃO</b> .....	<b>97</b>
<b>3.6. APÊNDICE</b> .....	<b>98</b>
<b>CAPÍTULO 4</b> .....	<b>100</b>
<b>4.1. RESUMO</b> .....	<b>100</b>
<b>4.2. CONTEXTUALIZAÇÃO</b> .....	<b>101</b>
4.2.1. ESTUDOS RELACIONADOS .....	102
4.2.2. MOTIVAÇÃO E CONTRIBUIÇÕES .....	108
4.2.3. ESTRUTURA DO CAPÍTULO .....	109
<b>4.3. METODOLOGIA</b> .....	<b>110</b>
4.3.1. <i>FRAMEWORK</i> PARA PREVISÃO DE PREÇOS .....	110
4.3.2. PRÉ-PROCESSAMENTO DOS DADOS .....	111
4.3.3. <i>MULTI-LAYER PERCEPTRON NEURAL NETWORKS</i> .....	112
4.3.4. <i>RECURRENT NEURAL NETWORKS</i> .....	113
4.3.5. <i>BIDIRECTIONAL RECURRENT NEURAL NETWORKS</i> .....	116
4.3.6. SELEÇÃO DE PREDITORES.....	117
4.3.7. <i>CROSS-VALIDATION</i> .....	118
4.3.8. MÉTRICAS E TESTE DE HIPÓTESES PARA A AVALIAÇÃO DE PERFORMANCE .....	118
<b>4.4. ESTUDO DE CASO</b> .....	<b>122</b>
4.4.1. MERCADO LIVRE DE ENERGIA BRASILEIRO .....	122
4.4.2. PREÇO DA ENERGIA CONVENCIONAL .....	122
4.4.3. PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS .....	123
4.4.4. CARGA .....	124

---

---

4.4.5.	ENERGIA ARMAZENADA .....	125
4.4.6.	ENERGIA NATURAL AFLUENTE.....	125
<b>4.5.</b>	<b>RESULTADOS.....</b>	<b>126</b>
4.5.1.	DESIGN DE EXPERIMENTOS.....	126
4.5.2.	PERFORMANCE POR TIPO DE REDE NEURAL .....	126
4.5.3.	IMPACTO DOS PREDITORES .....	131
4.5.4.	TESTE DE HIPÓTESES DE DIEBOLD-MARIANO .....	133
4.5.5.	AValiação DE ESTRATÉGIAS DE ATUAÇÃO .....	134
4.5.6.	OBSERVAÇÕES E DISCUSSÃO.....	138
<b>4.6.</b>	<b>CONCLUSÃO .....</b>	<b>142</b>
<b>4.7.</b>	<b>APÊNDICE .....</b>	<b>144</b>
<b>CAPÍTULO 5 .....</b>	<b>145</b>	
<b>5.1.</b>	<b>OBSERVAÇÕES FINAIS .....</b>	<b>145</b>
<b>5.2.</b>	<b>ESTUDOS FUTUROS .....</b>	<b>147</b>
<b>5.3.</b>	<b>PUBLICAÇÕES .....</b>	<b>148</b>
<b>REFERÊNCIAS BIBLIOGRÁFIAS .....</b>	<b>149</b>	

---

---

# CAPÍTULO 1

## INTRODUÇÃO

### 1.1. DEFINIÇÃO DO PROBLEMA

#### 1.1.1. CONTEXTO DA PESQUISA

A matriz elétrica brasileira é caracterizada pela participação elevada da fonte hidráulica em sua composição. Segundo o Balanço Energético Nacional elaborado em 2023 [1] pela Empresa de Pesquisa Energética (EPE), tal fonte representou cerca de 61,9% da oferta de energia em todo o Brasil no ano de 2022. No caso específico do Sistema Interligado Nacional (SIN), a capacidade instalada de usinas hidrelétricas chegou ao patamar de 48,7% do valor total em meados de maio de 2024, que corresponde à contribuição de mais de 160 aproveitamentos distribuídos em todos os subsistemas do SIN [2]. Em decorrência da fonte hidráulica ser dominante no Brasil e pelo fato da maior parte das usinas hidrelétricas estarem configuradas em cascata, o gerenciamento dos recursos disponíveis no SIN é balizado seguindo uma estrutura conhecida internacionalmente como *tight pool* [3], que essencialmente objetiva explorar os ganhos sinérgicos através da coordenação centralizada dos aproveitamentos. Nesse esquema, o agente responsável pela operação do sistema recebe informações detalhadas acerca dos recursos disponíveis (*e.g.*, disponibilidade das usinas, custo variável unitário, inflexibilidade, restrições operativas das usinas, entre outros) e determina a política operativa (assim como a programação da operação) segundo um critério econômico que, no caso brasileiro, é o uso eficiente dos recursos a fim de reduzir os custos totais de operação do SIN (o que inclui o custo de operação das usinas termelétricas e eventuais déficits de suprimento), atendendo ainda a um determinado nível de aversão ao risco.

Além das questões operativas citadas, o *tight pool* também é caracterizado pela energia ser valorada com base no Custo Marginal de Operação (CMO) calculado pelos mesmos modelos utilizados para a coordenação centralizada das usinas. No mercado de energia elétrica brasileiro, o CMO gera o Preço de Liquidação das Diferenças (PLD), que é calculado diariamente pela Câmara de Comercialização de Energia Elétrica (CCEE) através do encadeamento dos modelos NEWAVE (Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo) [4], DECOMP (Modelo de Planejamento da Operação de Sistemas

---

---

Hidrotérmicos Interligados de Curto Prazo) [5] e DESSEM (Modelo de Despacho Hidrotérmico de Curto Prazo) [6] (neste esquema, o DESSEM é o elo final da cadeia que gera diariamente o CMO para fins de cálculo do PLD). O PLD serve como preço de referência no Ambiente de Contratação Livre (ACL) para o caso de produtos com maturidade curta (*i.e.*, aqueles em que a energia contratada deve ser entregue em poucos meses à frente) e desempenha papel fundamental no processo de tomada de decisão dos agentes que atuam diariamente negociando a compra ou a venda de energia. Nesse ambiente, os agentes podem firmar contratos bilaterais de compra e venda de energia elétrica, nos quais especificam a quantidade de energia a ser entregue e o preço acordado. No entanto, devido à natureza dinâmica do mercado de energia e às variações na geração e no consumo, as quantidades reais de energia podem diferir das estipuladas nos contratos. Se a quantidade de energia efetivamente consumida ou gerada for diferente daquela especificada no contrato, a diferença será liquidada “ao sabor” do PLD, implicando na exposição desses agentes ao preço calculado pela CCEE.

No Brasil, há uma relação muito forte entre o PLD, a precipitação e as vazões que afluem aos aproveitamentos. São os modelos do tipo chuva-vazão, isto é, ferramentas matemáticas especializadas em prever a vazão de um curso d'água em resposta à precipitação, que calculam as vazões naturais afluentes aos aproveitamentos do SIN oficialmente utilizadas tanto no DECOMP quanto no DESSEM. Esses modelos são alimentados com as previsões de precipitação realizadas por sistemas numéricos de previsão do tempo que simulam o comportamento da atmosfera em todo o globo ou em parte dele. Em função da alta sensibilidade do PLD à disponibilidade futura de recursos hídricos, os agentes que atuam no ACL direcionam suas negociações de acordo com suas expectativas em relação ao comportamento futuro das variáveis hidrológicas, como precipitação e vazão. As grandes comercializadoras de energia, por exemplo, costumam ajustar suas estratégias de comercialização para o curto e médio prazo, com base em estimativas de preço feitas por meio de estudos utilizando os modelos NEWAVE e DECOMP, os quais consideram séries temporais de precipitação observada, vazão observada e, em casos mais sofisticados, vazões previstas por modelos chuva-vazão.

Os agentes que atuam no mercado buscam oportunidades que surgem com os movimentos de preço, muitas vezes ditados pela hidrologia e que são, em parte, antecipados por meio das projeções de PLD. No entanto, o processo de previsão de preços e tomada de decisão é extremamente complexo, exigindo esforço e conhecimento multidisciplinar. Na prática, a maioria das negociações de compra e venda leva em consideração as expectativas futuras em relação às condições energéticas do SIN. No entanto, essas expectativas não se fundamentam apenas em

---

---

análises matemáticas robustas; elas também incorporam as percepções pessoais dos agentes que atuam no mercado e as especulações sobre a atualização de outros tipos de dados, tais como a demanda por energia elétrica (se irá aumentar ou reduzir nas revisões mensais e trimestrais) e as restrições operativas de usinas estratégicas para a operação do SIN (*e.g.*, defluências mínimas de Porto Primavera e Jupiá, que podem ser modificadas para a preservação dos armazenamentos do Grande e Paranaíba).

### 1.1.2. QUALIFICAÇÃO DO PROBLEMA ABORDADO

A qualidade das previsões de PLD está fortemente atrelada à acurácia das previsões de precipitação e vazões naturais afluentes aos aproveitamentos do SIN. No curto prazo (*i.e.*, alguns dias à frente), é comum os agentes concentrarem seus esforços em apenas um único modelo chuva-vazão para a definição dos cenários a serem utilizados nas previsões de preço. Isso se deve majoritariamente ao esforço necessário para operacionalizar um sistema capaz de realizar diariamente previsões para todas as usinas hidrelétricas do SIN. Entretanto, adotar uma metodologia desse tipo é arriscado, pois não se leva em consideração a incerteza associada à previsão das afluições e nem aquela proveniente da precipitação calculada pelos sistemas de previsão de tempo. Além disso, é improvável que um único modelo chuva-vazão sempre consiga simular adequadamente o comportamento de todas as bacias hidrográficas no período seco, chuvoso e de transição, dado que tais modelos são apenas aproximações matemáticas imperfeitas. O ideal é que as principais fontes de incerteza sejam exploradas no processo de previsão de vazões através de um *Multi-model Ensemble* (MME) composto pela combinação de vários modelos chuva-vazão.

No médio prazo (*i.e.*, alguns meses à frente), a tratativa adotada para a previsão de preço é ainda mais rudimentar. Alguns agentes costumam realizar previsões utilizando as séries históricas de vazões afluentes (*i.e.*, selecionando os cenários que julgam mais prováveis de ocorrer novamente dado um critério específico) ou as vazões geradas através da execução de um chuva-vazão com as séries temporais de precipitação observada; nos casos mais sofisticados, as previsões sazonais de precipitação de modelos climáticos são utilizadas em substituição à precipitação observada. As duas primeiras metodologias mencionadas apresentam limitações, pois não levam em consideração o sinal de precipitação futura e se baseiam puramente em um conjunto de séries temporais que podem não se repetir no futuro em função das mudanças climáticas. Dessa forma, o primeiro passo a ser tomado em estudos voltados ao médio prazo consiste em aprimorar o sinal de

---

---

precipitação relacionado aos meses do horizonte temporal de previsão; o que consiste em uma tarefa computacionalmente custosa (*i.e.*, necessita do emprego de paralelismo de computadores ou de núcleos de processamento para o desenvolvimento de estudos nessa área) dada as dimensões do Brasil e a diversidade de fatores que afetam o clima de cada região.

No âmbito do ACL, onde os negócios são influenciados pelas previsões hidrológicas e pelas expectativas de atualização de outras variáveis relevantes do SIN, os agentes costumam monitorar diariamente a *Curva Forward* de preços negociados, bem como realizar estudos prospectivos com o intuito de antever a evolução temporal do mercado de energia para assim estabelecer estratégias de atuação. Apesar da ampla aplicação de algoritmos de *Machine Learning* para a previsão de preços e seus movimentos em mercados de ações, câmbio e criptomoedas, no Brasil, a previsão da *Curva Forward* de preços do ACL ainda não foi extensivamente explorada, especialmente através de arquiteturas mais avançadas de *Artificial Neural Networks*. Esta lacuna representa uma oportunidade significativa de pesquisa, dado que o mercado de energia possui dinâmicas complexas e multifatoriais que as técnicas avançadas de *Machine Learning* têm potencial de compreender e considerar em suas previsões. Além disso, a implementação de ferramentas do tipo pode agregar no sentido de informar o processo de tomada de posições no mercado, podendo potencializar os resultados econômicos em um setor crítico para o desenvolvimento nacional.

Tendo em vista a complexibilidade inerente ao processo de previsão de PLD e do comportamento do mercado livre de energia brasileiro (que se deve à elevada quantidade de usinas hidrelétricas no SIN, às incertezas associadas às previsões de precipitação/vazão e à especulação de fatores que vão além da hidrologia), bem como a importância de realizar previsões acuradas que orientem adequadamente a atuação dos agentes no ACL; propõe-se o desenvolvimento de metodologias que sejam capazes de aprimorar o processo de previsão de variáveis hidrológicas e do preço da energia firmado no ACL, a fim de informar a tomada de decisão dos agentes que negociam produtos de curto e médio prazo.

A problemática abordada na presente tese é de grande relevância para o mercado de energia elétrica brasileiro, visto que as soluções podem ser diretamente implementadas em plataformas computacionais a fim de auxiliar no processo de tomada de decisão dos agentes. Integrar resultados acadêmicos com aplicações práticas é essencial não apenas para o avanço do conhecimento científico, mas também para oferecer soluções tangíveis que beneficiem a sociedade e a economia. Tal contribuição promove o estreitamento dos laços entre a universidade e o setor

---

---

privado, reforçando a importância da colaboração entre essas esferas para impulsionar a inovação e o desenvolvimento no setor de energia.

## 1.2. OBJETIVOS

### 1.2.1. OBJETIVO GERAL

O objetivo geral da pesquisa proposta nesta tese é desenvolver metodologias para o aprimoramento da previsão de variáveis hidrológicas e da *Curva Forward* de preços negociados no ACL, bem como gerar produtos que sejam aplicáveis fora do ambiente acadêmico, fornecendo suporte às comercializadoras de energia durante o processo de tomada de decisão no mercado livre.

- O primeiro produto foca no curto prazo (dias à frente) e propõe a criação de um *framework* que explore a combinação de modelos chuva-vazão dirigidos pela precipitação prevista por diversos sistemas numéricos de previsão de tempo. As previsões geradas por tais cadeias compõem um MME cujos membros são combinados levando em consideração a incerteza associada;
- O segundo produto, por sua vez, é voltado para o médio prazo (meses à frente). Seu objetivo principal é aprimorar a previsão sazonal de precipitação em cada célula de uma grade sobre o Brasil utilizando *Machine Learning* e explorando a capacidade preditiva de modelos numéricos e índices climáticos relacionados aos padrões de teleconexão que afetam o Brasil;
- Já o terceiro produto, propõe a aplicação de redes neurais artificiais na previsão da *Curva Forward* de preços do ACL de produtos com maturidade de até 6 meses. Neste estudo também é feita uma análise do retorno financeiro que um agente comercializador obtém ao tomar posições (de venda ou compra) fundamentadas nas previsões realizadas pelas redes neurais.

Ademais, é importante enfatizar que a presente tese faz parte do **Programa de Doutorado Acadêmico para Inovação** promovido pelo **Conselho Nacional de Desenvolvimento Científico e Tecnológico**. Esse programa **visa desenvolver processos/produto de interesse para o setor empresarial elevando o potencial de inovação via pesquisas avançadas.**

### 1.2.2. OBJETIVOS ESPECÍFICOS

Uma vez definido o objetivo principal da tese, é necessário, então, detalhá-lo por meio de objetivos mais específicos que são:

---

- 
- Avaliar a acurácia e a eficiência das previsões de vazão a curto prazo feitas por diversas cadeias formadas a partir da combinação entre modelos chuva-vazão e sistemas numéricos de previsão de tempo;
  - Desenvolver um modelo *Bayesiano* para a previsão de vazão por conjunto que seja capaz de explorar a incerteza associada aos cenários considerados;
  - Avaliar a participação de cada cadeia chuva-vazão na composição da previsão de vazão por conjunto;
  - Avaliar as previsões de vazão por conjunto feitas pelo *framework* proposto e compará-las às previsões de cada membro do *ensemble*;
  - Avaliar a capacidade preditiva de modelos numéricos empregados na previsão sazonal de precipitação;
  - Propor modelos baseados em *Machine Learning* para o aprimoramento da previsão sazonal de precipitação de cada célula de uma grade sobre o Brasil;
  - Avaliar a aplicação de diversas arquiteturas de redes neurais artificiais na previsão da *Curva Forward* de preços do ACL, identificando aquela capaz de gerar previsões mais acuradas de preço;
  - Avaliar o retorno financeiro que um agente comercializador pode obter ao tomar posições (de venda ou compra) fundamentadas nas previsões realizadas pelas redes neurais.

### 1.3. ESTRUTURA DA TESE

A tese, organizada em formato de artigos, foi estruturada em 5 capítulos. O primeiro capítulo é dedicado à introdução do tema, enquanto os capítulos intermediários (2 a 4) correspondem a artigos científicos que foram publicados ou submetidos para publicação. O quinto capítulo apresenta a conclusão, amarrando os conceitos discutidos ao longo do trabalho. Os temas dos capítulos estão ordenados de forma a apresentar os conceitos na sequência em que são necessários para o entendimento progressivo do trabalho.

**CAPÍTULO 1 – INTRODUÇÃO:** é feita uma exposição do contexto em que a pesquisa se insere, da qualificação do problema abordado e dos objetivos gerais e específicos.

---

---

**CAPÍTULO 2 – PONDERAÇÃO BAYESIANA DE MODELOS HIDROLÓGICOS APLICADA À PREVISÃO DE VAZÕES NO ÂMBITO DO SISTEMA INTERLIGADO NACIONAL BRASILEIRO:** o objetivo deste capítulo é apresentar de forma integral o *framework* desenvolvido para a realização de previsões diárias de vazão por meio de um MME. Para isso, é feita uma exposição dos modelos chuva-vazão adotados, apresentação da metodologia Bayesiana aplicada para a combinação dos modelos considerando a incerteza relacionada, avaliação da performance individual dos membros que compõem o *ensemble* e da previsão final obtida com a combinação dos membros.

**CAPÍTULO 3 – APLICAÇÃO DE TÉCNICAS DE *MACHINE LEARNING* E ÍNDICES CLIMÁTICOS PARA O APRIMORAMENTO DA PREVISÃO SAZONAL DE PRECIPITAÇÃO NO BRASIL:** o propósito deste capítulo é apresentar o *framework* criado para o aprimoramento das previsões sazonais de precipitação no Brasil. Para isso, é feita uma exposição do problema abordado, das regiões brasileiras consideradas no estudo, dos dados e métodos desenvolvidos utilizando técnicas lineares ou não e, por fim, é realizada uma avaliação da performance das previsões realizadas pelos modelos propostos.

**CAPÍTULO 4 – PREVISÃO DA CURVA FORWARD DE PREÇOS DA ENERGIA CONVENCIONAL USANDO REDES NEURAS ARTIFICIAIS:** o objetivo deste capítulo é explorar a aplicação de diversas arquiteturas de redes neurais artificiais para a previsão da *Curva Forward* de preços do mercado livre de energia brasileiro. Para isso, é feita uma exposição do problema abordado, das arquiteturas de redes neurais testadas, do conjunto de preditores considerados e dos resultados obtidos na avaliação da acurácia das previsões realizadas pelos modelos ao longo de um período de teste. É discutido também o retorno financeiro que seria obtido caso os modelos fossem utilizados por um agente comercializador.

**CAPÍTULO 5 – CONCLUSÕES:** neste capítulo é realizada uma explanação dos principais resultados obtidos até o momento e dos próximos passos a serem seguidos para a continuação da pesquisa.

---

---

# CAPÍTULO 2

## PONDERAÇÃO BAYESIANA DE MODELOS HIDROLÓGICOS APLICADA À PREVISÃO DE VAZÕES NO ÂMBITO DO SISTEMA INTERLIGADO NACIONAL BRASILEIRO

### 2.1. RESUMO

Este capítulo propõe um novo *framework* baseado em *Bayesian Model Averaging* (BMA) para a previsão de vazões afluentes aos reservatórios e hidrelétricas do SIN. BMA é um método estatístico capaz de combinar modelos utilizando suas distribuições de probabilidade *a posteriori*. Previsões determinísticas de vazão, para um horizonte temporal de previsão de 11 dias, são produzidas pela ponderação dos membros de um *Multi-model Ensemble* (MME) composto pelos resultados das execuções do Modelo de Grandes Bacias (MGB), do *Soil Moisture Accounting Procedure* (SMAP) e de *Artificial Neural Networks* (ANNs) dirigidos pela precipitação do *Global Ensemble Forecast System* (GEFS), do *ETA Model* (ETA), do *Global Forecast System* (GFS) e do *Atmospheric Model Ensemble 15-day forecast* (ENS). Os pesos aplicados são dinâmicos, isto é, recalculados periodicamente com dados recentes das séries históricas de vazões previstas e observadas. A seleção de membros com bom desempenho é capaz de melhorar a performance do *ensemble*. Por esse motivo, o princípio de *Occam's Razor* é aplicado para o descarte dos membros com performance inferior. O *framework* foi testado via simulações de *backtest* para as vazões afluentes de um conjunto de 139 reservatórios e hidrelétricas do SIN no período definido entre 2019 e 2020. As previsões obtidas com os membros individuais do *ensemble* e o cenário determinístico calculado via BMA foram analisados utilizando as métricas *Mean Absolute Percentual Error* (MAPE), *Nash-Sutcliffe Efficiency Coefficient* (NSE), Distância Multicritério (DM) e o teste de hipóteses de Diebold-Mariano. Os resultados obtidos demonstram que o *framework* proposto é capaz de gerar em média previsões melhores que as dos membros individuais do *ensemble* para todo o Brasil, principalmente no caso dos reservatórios e hidrelétricas

---

localizados nas regiões Sul, Centro-Oeste e Sudeste nos primeiros dias do horizonte temporal de previsão.

## 2.2. CONTEXTUALIZAÇÃO

A água proveniente de rios é um recurso limitado e essencial em atividades como irrigação, geração de energia hidrelétrica, navegação, abastecimento de indústrias e saneamento básico [7]. Os agentes responsáveis pelo planejamento e gerenciamento do uso desse recurso utilizam modelos hidrológicos para a definição de cenários de vazão para horizontes temporais variados [8], [9], [10], [11]. Contudo, modelos matemáticos dessa natureza são afetados por diversas fontes de incerteza que acabam interferindo na sua capacidade preditiva, o que pode levar a previsões de baixa confiabilidade que podem comprometer todo o trabalho realizado pelo agente planejador [12]. Com o propósito de evitar tal situação, é importante atentar às incertezas associadas aos preditores (*e.g.*, vazões observadas e precipitação prevista), estrutura matemática (*i.e.*, tipo e arquitetura do modelo), condições iniciais e parâmetros definidos durante a calibração [13], [14], [15], [16] de qualquer modelo utilizado durante o processo de planejamento. Uma forma de explorar as fontes de incerteza é por meio da técnica de previsão de vazão por conjunto [17], [18], [19], [20], [21]. Nesta metodologia, modelos do tipo chuva-vazão [22] com estruturas, calibrações, condições iniciais ou *inputs* distintos são desenvolvidos e utilizados para a composição de um conjunto de cenários de vazão [23] que podem ser combinados para a formação de uma previsão probabilística de vazão por conjunto, ou para a construção de um novo modelo matemático responsável pela combinação dos membros do conjunto.

No Brasil, o ONS é a instituição responsável pelo planejamento da operação do SIN. O SIN consiste em um sistema de geração e transmissão de energia do tipo hidro-termo-eólico-solar de grande porte com predominância de geração hidrelétrica [24]. Mais de 160 reservatórios e hidrelétricas, distribuídos em todas as regiões do Brasil, são controlados pelo operador [25]; o que representa cerca de 48,7% da capacidade instalada de geração de todo o SIN [2] até meados de maio de 2024. Em função da expressiva participação da fonte hidráulica, o ONS toma decisões operativas considerando os usos múltiplos da água e a disponibilidade futura de recursos hídricos. Para isso, o operador aplica uma gama de modelos preditores na construção dos cenários de vazão em escala diária, semanal e mensal. As previsões de vazão são utilizadas na programação diária da operação do SIN e no cálculo do PLD que é realizado pela CCEE. Na composição de tais cenários, apenas as vazões do mês operativo vigente são computadas por meio de modelos chuva-

---

vazão [22] alimentados com as previsões de precipitação de modelos numéricos que simulam a atmosfera [26].

Ao longo dos anos, a metodologia adotada pelo operador para a composição do conjunto de previsões de vazões passou por aprimoramentos significativos. Inicialmente, o ONS utilizava para cada bacia um tipo de modelo chuva-vazão distinto, como, por exemplo: um baseado em Lógica Fuzzy na bacia do rio Iguaçu [27]; o Modelo de Grandes Bacias (MGB) do Instituto de Pesquisa Hidráulicas na bacia do rio Paranaíba [28]; redes neurais artificiais na bacia do rio São Francisco [29]; o *Soil Moisture Accounting Procedure* (SMAP) nas bacias do Baixo Grande [30] e Alto Paranaíba [31]; e o SMAP com Modelagem Estocástica Linear (MEL), ou SMAP-MEL, no trecho incremental à Itaipu [32]. Enquanto os modelos citados permaneceram ativos, o ONS pôde avaliar as metodologias utilizadas, o desempenho das previsões, e os aspectos operacionais como tempo de processamento e facilidade de integração da tecnologia com ferramentas de gerenciamento. Tendo em vista a dificuldade em lidar com vários modelos ao mesmo tempo, e a necessidade de tornar o processo de previsão de vazões mais transparente, o ONS optou, em 2018, por substituir os modelos antigos, e utilizar uma versão modificada do modelo SMAP (SMAP/ONS) para a previsão das vazões afluentes aos reservatórios e hidrelétricas do SIN [33].

Além da padronização de um único tipo de modelo chuva-vazão, o ONS também passou a utilizar a combinação das previsões realizadas pelos modelos numéricos de previsão de tempo Eta (ETA) [34], [35], do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), e o *Global Ensemble Forecast System* (GEFS) [36], do *National Centers for Environmental Prediction* (NCEP), para a construção de um cenário determinístico de precipitação prevista. Essa metodologia foi nomeada de previsão de precipitação por conjunto [37], que consiste basicamente em calcular uma média ponderada com as previsões do ETA e GEFS, cujos pesos são definidos pelo quadrado das correlações verificadas entre as séries históricas de previsões de cada modelo e a precipitação observada. Em 2019, tal metodologia baseada em correlações foi substituída por outra em que os pesos são calculados por meio da resolução de um problema de programação matemática (*i.e.*, problema composto por uma função objetivo a ser minimizada respeitando um conjunto de restrições de desigualdade) [38]. Basicamente, o problema citado visa minimizar a diferença entre a precipitação calculada por conjunto e a precipitação observada nos últimos 120 dias corridos, considerando os erros na precipitação total acumulada diariamente e o erro de volume (*i.e.*, totais acumulados de vários dias). Ademais, o ONS anunciou a introdução de um novo modelo numérico [39] para a composição da precipitação por conjunto, o *Atmospheric Model Ensemble 15-day Forecast* (ENS) do *European Centre for Medium-Range Weather Forecasts*

---

---

(ECMWF) [40]. A partir daí, as previsões de precipitação que alimentam o SMAP/ONS passaram a ser o resultado da combinação dos membros de um *ensemble*.

Até então, a abordagem adotada pelo ONS para tratar a principal fonte de incertezas que afeta o processo de planejamento da operação do SIN a curto prazo (*i.e.*, incertezas provenientes das vazões previstas) visa majoritariamente aquelas oriundas da previsão de precipitação. Entretanto, dado que os modelos do tipo chuva-vazão não conseguem representar perfeitamente o comportamento das bacias hidrográficas simuladas devido serem apenas aproximações matemáticas; torna-se evidente a necessidade de levar em consideração as incertezas inerentes ao modelo chuva-vazão, e não apenas aquelas associadas à precipitação futura, como é adotado no procedimento padrão do ONS.

### 2.2.1. ESTUDOS RELACIONADOS

Neste contexto, a literatura aborda algumas metodologias para o aprimoramento de previsões de vazão por meio de um conjunto de modelos. Uma das vertentes mais promissoras faz uso de *Artificial Neural Networks* (ANNs) para a criação de uma *Ensemble Neural Network* (ENN). Uma ENN consiste em um conjunto de ANNs independentes que possuem características estruturais ou variáveis preditoras distintas. As previsões realizadas pelas ANNs são combinadas de forma a gerar um cenário final único para a variável de interesse [41], [42], [43], técnica conhecida como *Bootstrap Aggregation* ou *Bagging*. Além dessa aplicação, também é possível utilizar uma ANN para a combinação das previsões geradas por outros modelos que não são necessariamente ANNs [44]. Além das ANNs, destacam-se outros métodos estatísticos, como *Constant Coefficient Regression*, *Switching Regression* e *Sum of Squared Error* para a combinação dos membros de um *ensemble* por meio de regressões [45]; o autor do estudo observa que eles são capazes de reduzir consideravelmente o erro do conjunto quando os membros não possuem viés. Já em [46], é explorado o conceito de *Multi-model Ensemble* (MME), em que os modelos são combinados via pesos calculados de acordo com suas habilidades preditivas individuais. Em [47], o autor avalia a aplicação de quatro técnicas de combinação, *Linear Regression*, *Quantile Mapping*, *Quantile Model Averaging* e *Bayesian Model Averaging* (BMA), em um *ensemble* gerado por dois modelos chuva-vazão distintos, sistema conhecido como *Multi-model Ensemble Streamflow Prediction*.

As técnicas baseadas em MME tem ganhado notoriedade nos últimos anos. Elas são caracterizadas por utilizar informações relacionadas à capacidade preditiva dos modelos de um

---

---

conjunto para a formação de uma previsão mais robusta. Um dos principais tipos de MME é a BMA [48]. Esse método busca evitar os problemas que surgem quando um único modelo é selecionado (*true model*), como a desconsideração das incertezas envolvidas e o excesso de confiança nas previsões do modelo solitário. Na BMA, a incerteza associada a cada modelo é modelada por meio de uma distribuição de probabilidades *a posteriori*, que é determinada via inferência Bayesiana. A integração dessas distribuições gera um conjunto de pesos que é normalizado e aplicado no cálculo da média ponderada das previsões. Durante muito tempo, a aplicação de BMA em problemas de grande porte foi computacionalmente inviável por não existirem técnicas que possibilitasse a determinação das distribuições *a posteriori* dos modelos. No entanto, com o desenvolvimento computacional e de novos algoritmos, essa realidade foi alterada. A exemplo disso, em [49] e [50], são exploradas duas alternativas para a contabilização da incerteza de modelos matemáticos de previsão: a) um procedimento *ad hoc* denominado *Occam's Window* que reduz o conjunto de modelos utilizado na composição da média seguindo o princípio de que os *membros* com desempenho substancialmente inferior ao do melhor modelo devem ser descartados; e b) a aplicação *Markov Chain Monte Carlo* para a determinação de uma aproximação das distribuições *a posteriori* utilizadas no cálculo dos pesos.

Alguns dos autores que já exploraram essa metodologia afirmam que a aplicação de BMA normalmente consegue produzir um resultado melhor que o dos membros individuais do *ensemble* [16], [51] em diversos regimes de vazão [52]. Isso se deve majoritariamente a capacidade que ela tem de assimilar a performance relativa dos modelos via distribuições de probabilidade corrigidas por observações. Essa questão é exemplificada em diversos trabalhos [53], [54] que investigam o uso de ponderação Bayesiana de modelos hidrológicos no desenvolvimento de previsões probabilísticas mais acuradas e confiáveis. Em [53], por exemplo, o autor mostra que a combinação das previsões de modelos que capturam certos aspectos do hidrograma, como, por exemplo, vazões médias, baixas e picos, apresenta melhor performance que os membros individuais, principalmente quando se adota uma abordagem baseada em vários conjuntos de pesos (*i.e.*, um conjunto de peso por nível de vazão). De forma similar, no estudo desenvolvido por Souza Filho *et al.* [55], os autores propuseram um MME composto por modelos de previsão sazonal integrados a modelos hidrológicos chuva-vazão e modelos estocásticos baseados em *Machine Learning*. Nessa abordagem, a BMA foi utilizada para combinar as previsões de acordo com classes baseadas nos percentis 20, 40, 60 e 80 das séries temporais de vazões (ou seja, vazões muito baixas, baixas, normais, altas e muito altas), para cada mês do ano, já descartando os membros do conjunto com

---

baixo desempenho. Como resultado, foi observado que a BMA foi capaz de gerar previsões mais precisas do que os membros do *ensemble*.

### 2.2.2. PROPÓSITO DA PESQUISA

Tendo em vista os benefícios da previsão de vazões por conjunto e a predominância de geração hidrelétrica no SIN, esta pesquisa propõem um novo *framework* fundamentado em BMA para a geração de um cenário único de vazões diárias para cada um dos reservatórios e hidrelétricas relevantes do SIN. A aplicação dessa metodologia no caso brasileiro visa incorporar informações relativas à incerteza estrutural dos modelos hidrológicos ao processo de previsão de vazões, contribuindo, portanto, para a formação de cenários mais robustos para aplicações como programação da operação e previsão do preço da energia nos submercados do SIN. A metodologia proposta aqui destaca-se por:

- Explorar a aplicação de pesos dinâmicos, os quais são atualizados semanalmente em resposta às novas medições de vazão, considerando uma janela móvel de 120 dias de dados. Consequentemente, as previsões de vazão estão mais alinhadas com a realidade, já que pesos estáticos não consideram o desempenho preditivo variável dos modelos chuva-vazão à medida que os níveis de vazão mudam;
- Incorporar o princípio de *Occam's Razor* de Raftery *et al.* [49] e Hoeting *et al.* [50] para a seleção de membros de qualidade de um conjunto prévio de modelos. O *approach* proposto aqui difere de [49] e [50] por não limitar os pesos dos modelos ao mesmo valor. Como consequência, membros com desempenho inferior são descartados evitando a degradação das previsões da BMA, dado que a contribuição conjunta de modelos com menor performance afeta fortemente os resultados finais;
- Ter sido testada em um sistema real de grande porte, dado que um dos objetivos é desenvolver uma ferramenta de previsão confiável que possa ser utilizada no apoio operacional de hidrelétricas e em estudos de mercado;
- Ter sido avaliada levando em conta a variabilidade espacial do sistema hidrelétrico de grande porte brasileiro. Um teste de hipótese também foi aplicado a fim de comparar a acurácia preditiva da BMA com a dos membros individuais do *ensemble*.

### 2.2.3. ESTRUTURA DO CAPÍTULO

O capítulo está organizado em cinco seções. A Seção 2.2 discorre sobre a aplicação de modelos hidrológicos para previsão no âmbito do SIN e apresenta algumas metodologias para a

---

formação de um *ensemble*. A Seção 2.3 apresenta a área de estudo, dados utilizados e o *framework* criado utilizando BMA. A Seção 2.4 discute os resultados da aplicação do *framework* para a previsão de vazões afluentes aos reservatórios e hidrelétricas do SIN. Por fim, a Seção 2.5 conclui este capítulo.

## 2.3. METODOLOGIA

### 2.3.1. ÁREA DE ESTUDO

A área de estudo corresponde àquela que abrange o SIN. Ele é um sistema de grande porte do tipo hidro-termo-eólico-solar com predominância de usinas hidrelétricas de múltiplos proprietários configuradas majoritariamente em cascatas [24]. Devido a sua grande dimensão e às diferenças regionais, o SIN é dividido em quatro subsistemas, que são: Centro-Oeste/Sudeste, Sul, Nordeste e Norte. A geração hidráulica predomina em todos os subsistemas, exceto no Nordeste (em que a geração eólica predomina), e é proveniente de hidrelétricas localizadas em bacias

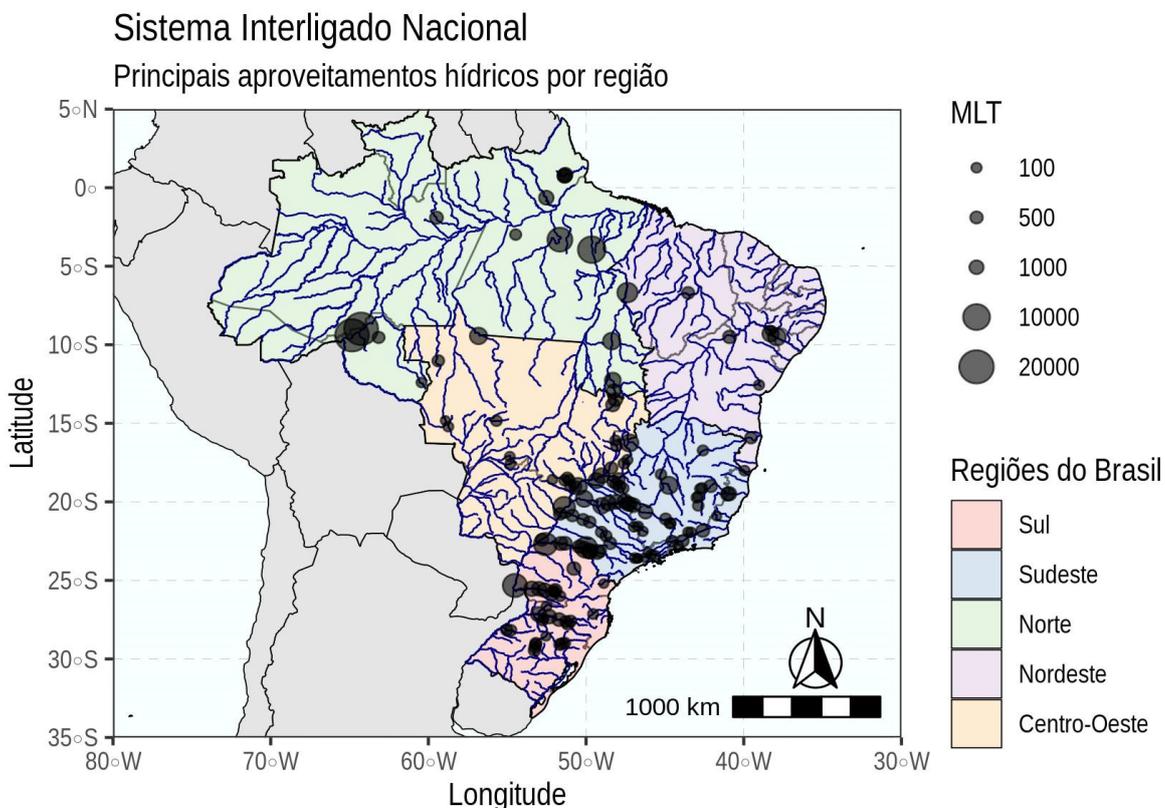


Figura 1 - Principais reservatórios e hidrelétricas do SIN por subsistema (Sul, Centro-Oeste/Sudeste, Nordeste e Norte). No mapa, a vazão Média de Longo Termo (MLT) anual [ $m^3/s$ ] é utilizada para destacar os aproveitamentos de acordo as vazões médias entre 1931 e 2020.

hidrográficas de regimes hidrológicos variados. Ao todo, o ONS coordena mais de 160 hidrelétricas e reservatórios distribuídos em 22 bacias e sub-bacias (Grande, Paranaíba, Tietê, Paranapanema, Alto Paraná, Baixo Paraná, Alto Tietê, Paraíba do Sul, Itabapoana, Mucuri, Doce, Paraguai, Jequitinhonha, Amazonas, São Francisco e Tocantins) pertencentes a 11 regiões hidrográficas [25]. Cada aproveitamento tem suas vazões afluentes monitoradas por meio de postos fluviométricos localizados em trechos específicos de rios que banham o Brasil. Os dados coletados diariamente são utilizados como insumo dos diversos modelos aplicados na programação da operação e do SIN. No estudo conduzido nesse capítulo, os dados de 139 aproveitamentos indicados na Figura 1 são utilizados para o teste do *framework* proposto.

### 2.3.2. DADOS

#### 2.3.2.1. Vazões Naturais

As séries históricas de vazões naturais diárias dos aproveitamentos da Figura 1 estão disponíveis no portal SINtegre do ONS [56]. Atualmente, as séries oficiais iniciam em janeiro de 1931 e terminam em dezembro de 2019. Anualmente, o operador lança oficialmente uma atualização do banco de dados com novas informações através da planilha “Vazões\_Diárias\_1931\_XXXX”, onde “XXXX” é o último ano contemplado pela série, disponível no sítio eletrônico [57]. As vazões naturais são reconstituídas utilizando dados fornecidos pelos agentes responsáveis pelos postos fluviométricos em um processo que contabiliza os efeitos da operação dos reservatórios a montante, a evaporação líquida de água e usos consuntivo, conforme discorre a Nota Técnica 144 de 2018 - Metodologia de Reconstituição e Tratamento das Vazões Naturais [58]. Vazões recentes, que não constam no arquivo “Vazões\_Diárias\_1931\_XXXX”, são disponibilizadas diariamente através de três planilhas: “Relatório Diário de Situação Hidráulico-Hidrológica das Usinas Hidrelétricas do SIN”, “Relatório de Acompanhamento das Condições Hidráulico-Hidrológicas dos Reservatórios” e o “Relatório de Acompanhamento Hidrológico”, disponíveis no sítio eletrônico [59]. Os dados citados foram utilizados para a composição das séries históricas de vazões naturais completas (*i.e.*, de 1931 até 2020) para todos os postos fluviométricos do estudo, formando um produto denominado “QObs”.

### 2.3.2.2. Análise de Precipitação

As séries históricas de precipitação utilizadas neste estudo são as do produto MERGE desenvolvido pelo CPTEC. O MERGE é uma análise de precipitação formada pela combinação de dados estimados por satélite com dados observados. A princípio, o CPTEC utilizava estimativas de precipitação feitas pelo sensor *Tropical Rainfall Measuring Mission* (TRMM) (que operou entre 1997 e 2015) [60] para a composição do MERGE-CPTEC-TRMM, onde os totais acumulados diários de precipitação da América do Sul (82,8°W-34°W e 52,2°S-12,2°N) eram disponibilizados diariamente [61]. Com a desativação do TRMM em 2015, o CPTEC passou a utilizar os dados do *Global Precipitation Measurement (GPM) Integrated Multi-Satellite Retrievals for GPM* (IMERG) [62], substituindo o MERGE-CPTEC-TRMM pelo produto diário MERGE-CPTEC-GPM. A nova versão do MERGE abrange toda a América do Sul, possui uma resolução espacial horizontal de 0,1° e acumula a precipitação entre 12:00 e 12:00 UTC [63]. Com relação à performance do produto, estudos mostram que o MERGE-CPTEC-GPM consegue representar satisfatoriamente o regime de precipitação em várias regiões do Brasil [63], [64]. Os dados desse produto podem ser acessados através do sítio eletrônico [65].

### 2.3.2.3. Previsão de Precipitação

Quando valores históricos de precipitação observada não estão disponíveis, como ocorre na aplicação de modelos chuva-vazão em problema de previsão, a precipitação calculada por modelos numéricos de previsão de tempo do tipo global (*i.e.*, modelos que determinam a circulação geral da atmosfera através da modelagem do sistema climático e suas interações) ou regional (*i.e.*, modelos que simulam o sistema climático em apenas uma determinada parte do globo) é utilizada em substituição [66]. No presente estudo, são utilizados dados de quatro modelos descritos na Tabela 1.

Tabela 1 - Modelos Numéricos de Previsão de Tempo.

Modelo	Detalhes	Link
<i>Global Ensemble Forecast System version 11</i> (GEFS)	O GEFS é um sistema numérico global de previsão de tempo com horizonte temporal de previsão de 16 dias. Ele foi desenvolvido pelo <i>National Centers for Environmental Prediction</i> (NCEP) e implementado de dezembro de 2016 até setembro de 2020, com execuções às 00, 06, 12 e 18 UTC. Em cada uma delas, o GEFS 11 gerava 21 cenários de precipitação total dos quais um deles é o cenário base, ou membro controle, e os demais cenários são gerados considerando perturbações nas condições de inicialização do modelo numérico, também conhecidos como membros de perturbação [67]. Para esse estudo, os resultados das execuções das 18 UTC, entre os anos 2018 e 2020, foram baixados diariamente em resolução espacial de 1°.	<a href="https://ftp.ncep.noaa.gov/data/nccf/com/gensprod/">https://ftp.ncep.noaa.gov/data/nccf/com/gensprod/</a> .

<p><i>Global Forecast System (GFS)</i></p>	<p>O GFS é um sistema numérico global de previsão de tempo, também desenvolvido pelo NCEP, que acopla modelos numéricos individuais da atmosfera, oceano, terra e gelo marinho. Ele é executado diariamente às 00, 06, 12 e 18 UTC, gerando sempre um único cenário com horizonte temporal de previsão de 16 dias [68]. De forma similar ao adotado para o caso do GEFS, os resultados das execuções do GFS das 18 UTC, entre os anos 2018 e 2020, foram baixados diariamente em resolução espacial de 0,25°.</p>	<p><a href="https://ftp.ncep.noaa.gov/data/nccf/com/gfs/prod/">https://ftp.ncep.noaa.gov/data/nccf/com/gfs/prod/</a>&gt;.</p>
<p><i>ETA Model (ETA)</i></p>	<p>O ETA é um modelo numérico regional de previsão de tempo que foi desenvolvido pela Universidade de Belgrado em conjunto com o Instituto de Hidrometeorologia da Iugoslávia [34]. Tornou-se operacional no CPTEC na década de noventa e vem sendo utilizado até o presente na realização de previsão de tempo para a América do Sul. Sua resolução espacial é de 0,4° e seu horizonte temporal de previsão é de 11 dias. Os resultados das execuções do modelo ETA, entre os anos de 2018 e 2020, foram baixados diariamente através de um link que não está mais disponível, entretanto, o ONS atualmente disponibiliza dados do modelo através do SINtegre.</p>	<p><a href="https://sintegre.ons.org.br/sites/9/38/paginas/produtos-dinamicos/meteorologia.aspx">https://sintegre.ons.org.br/sites/9/38/paginas/produtos-dinamicos/meteorologia.aspx</a></p>
<p><i>Atmospheric Model Ensemble 15-day forecast (ENS)</i></p>	<p>O ENS [40], [69] é um <i>dataset</i> com resolução espacial de 0,20° e horizonte temporal de previsão de 15 dias gerado pelo sistema numérico global de previsão de tempo do ECMWF. O ENS é composto por 1 membro de controle e 50 membros de perturbação que são gerados por meio de execuções diárias realizadas às 00, 06, 12 e 18 UTC. Apesar do produto original ser um <i>ensemble</i>, a autora deste trabalho não teve acesso aos membros individuais do ENS, mas sim à média dos membros através do SINtegre.</p>	<p><a href="https://sintegre.ons.org.br/sites/9/38/paginas/produtos-dinamicos/meteorologia.aspx">https://sintegre.ons.org.br/sites/9/38/paginas/produtos-dinamicos/meteorologia.aspx</a></p>

### 2.3.3. MODELOS CHUVA-VAZÃO SIMULADOS

#### 2.3.3.1. Previsão de Vazões via MGB

O MGB [70], [71] do Instituto de Pesquisas Hidráulicas é um modelo distribuído (*i.e.*, considera a variabilidade física-espacial da região modelada) que simula os processos hidrológicos de bacias hidrográficas de grande porte (*i.e.*, com milhares de  $km^2$  e até dimensões continentais) em resolução temporal diária. Sua composição engloba expressões matemáticas conceituais que simulam o balanço de água e energia no solo, interceptação de água no dossel das plantas, evapotranspiração das plantas e evaporação da água no solo, escoamento superficial, subsuperficial, subterrâneo, além de expressões físicas para o caso da propagação das vazões ao longo da rede de drenagem [72]. No processo de modelagem, a bacia hidrográfica é dividida em unidades espaciais de contribuição a um segmento de rio, semelhantes a pequenas bacias hidrográficas incrementais, chamadas de minibacias. Cada tipo de escoamento gerado possui velocidade de propagação distinta. A representação dessa característica dentro de uma minibacia é feita através da passagem desses escoamentos por um conjunto de três reservatórios lineares: superficial, subsuperficial e subterrâneo. No estudo apresentado neste capítulo, o MGB foi calibrado com as vazões naturais da rede hidrométrica da Agência Nacional de águas (ANA) e a

---

precipitação observada nas estações pluviométricas da ANA e do Serviço Nacional de Meteorologia e Hidrologia da Bolívia entre 2001 e 2015 [73], [74]. As previsões foram realizadas utilizando dados históricos de precipitação do MERGE, vazões do QObs e as precipitações do GEFS, GFS e ETA entre os anos de 2019 e 2020. Dessa forma, foram gerados 6 conjuntos de previsões: a) o GEFS-MGB, obtido pela execução do MGB alimentado pela média dos membros do GEFS; b)  $\text{inf}(\text{GEFS-MGB})$ , que é o cenário mais pessimista obtido pela execução do MGB com cada um dos membros individuais do GEFS (*i.e.*, que projeta as menores vazões); c)  $\text{median}(\text{GEFS-MGB})$ , que é a mediana calculada com os resultados da execução do MGB com cada um dos membros do GEFS; d) o  $\text{sup}(\text{GEFS-MGB})$ , que é o cenário mais otimista obtido pela execução do MGB com cada um dos membros individuais do GEFS (*i.e.*, que projeta as maiores vazões); e) o ETA-MGB; e f) o GFS-MGB.

### 2.3.3.2. Previsão de Vazões via SMAP

O SMAP [75] é um modelo conceitual de simulação hidrológica (*i.e.*, usa equações empíricas para a modelagem dos processos hidrológicos) do tipo concentrado (*i.e.*, desconsidera informações espaciais da bacia, tais como características físicas irregulares). Sua composição engloba expressões matemáticas que contabilizam o balanço de água no solo, evapotranspiração, escoamento superficial, escoamento de planície e escoamento subterrâneo. Na sua versão original, o SMAP modela o processo de transferência de água por meio de três reservatórios lineares fictícios, que são: o reservatório de solo; o reservatório da superfície, associado ao escoamento superficial; e o reservatório subterrâneo, associado ao escoamento subterrâneo da bacia. Na versão adotada pelo ONS (SMAP/ONS), foi acrescentado um reservatório de planície [33] que visa melhorar a representação do escoamento superficial. Quanto aos dados de entrada do modelo, são considerados os totais diários de precipitação observada, precipitação prevista (*i.e.*, previsão por conjunto utilizando o ETA, GEFS e ENS), totais climatológicos de evaporação potencial e vazões diárias observadas [33]. Neste estudo, foram utilizadas as previsões feitas com os decks de arquivos de entrada oficiais do SMAP/ONS, entre os anos de 2019 e 2020, disponíveis atualmente no sítio eletrônico [76]. Ademais, informações sobre a calibração do modelo chuva-vazão podem ser obtidas através da nota técnica ONS 97/2018-RV7 [77].

---

### 2.3.3.3. Previsão de Vazões via Redes Neurais Artificiais

As ANNs [78], [79] são estruturas matemáticas inspiradas nas redes neurais biológicas. Sua arquitetura é fundamentada em camadas de neurônios artificiais que trocam informações entre si, e que possuem a capacidade de adquirir conhecimento a partir de um processo de treinamento com dados históricos [80]. Depois de treinadas, as ANNs adquirem a capacidade de realizar classificação de dados ou previsões relacionadas a uma variável de interesse, dependendo da aplicação proposta. Redes do tipo *Multi-Layer Perceptron* [81] são tipicamente formadas por três tipos de camadas de neurônios que processam informações no sentido da camada de entrada para a camada de saída. Para o caso das ANNs individualizadas, que foram desenvolvidas para realizar previsões de vazão afluente aos reservatórios e hidrelétricas do SIN, a camada de entrada é responsável por receber os dados referentes à precipitação prevista pelo GEFS e vazões diárias observadas. Essas informações  $u_i$  são repassadas à primeira camada intermediária que aplica combinações lineares  $\sum_{i=1}^n s_i u_i$  via pesos  $s_i$  em cada um de seus neurônios, soma-as a um viés  $b$  e submete o resultado a uma não linearidade (*i.e.*, função de ativação  $f(\cdot)$ ). Após repetir o procedimento anterior de forma sequencial para cada camada do tipo intermediária, a camada de saída recebe o resultado desse processamento, realiza uma combinação linear e gera a previsão associada à variável de interesse. Neste estudo, foram utilizadas as previsões feitas pelas ANNs entre 2019 e 2020. Mais informações sobre o modelo utilizado e sua calibração podem ser obtidas no artigo [82].

### 2.3.4. CADEIAS CHUVA-VAZÃO

A Figura 2 apresenta as cadeias do tipo chuva-vazão cujas previsões compõem o *ensemble* utilizado para a computação da BMA. Neste estudo, o termo cadeia chuva-vazão se refere à combinação dos resultados dos modelos numéricos de previsão de tempo com os modelos chuva-vazão. No total, foram geradas oito cadeias das quais três se originam do MGB combinado ao GFS, ETA e à média dos membros do GEFS; outras três são os cenários pessimista, otimista e mediano obtidos pela avaliação do conjunto de execuções do MGB com cada membro do GEFS; um proveniente da combinação do GEFS com as ANNs; e um último membro proveniente da execução do SMAP/ONS com o resultado da previsão de precipitação por conjunto.

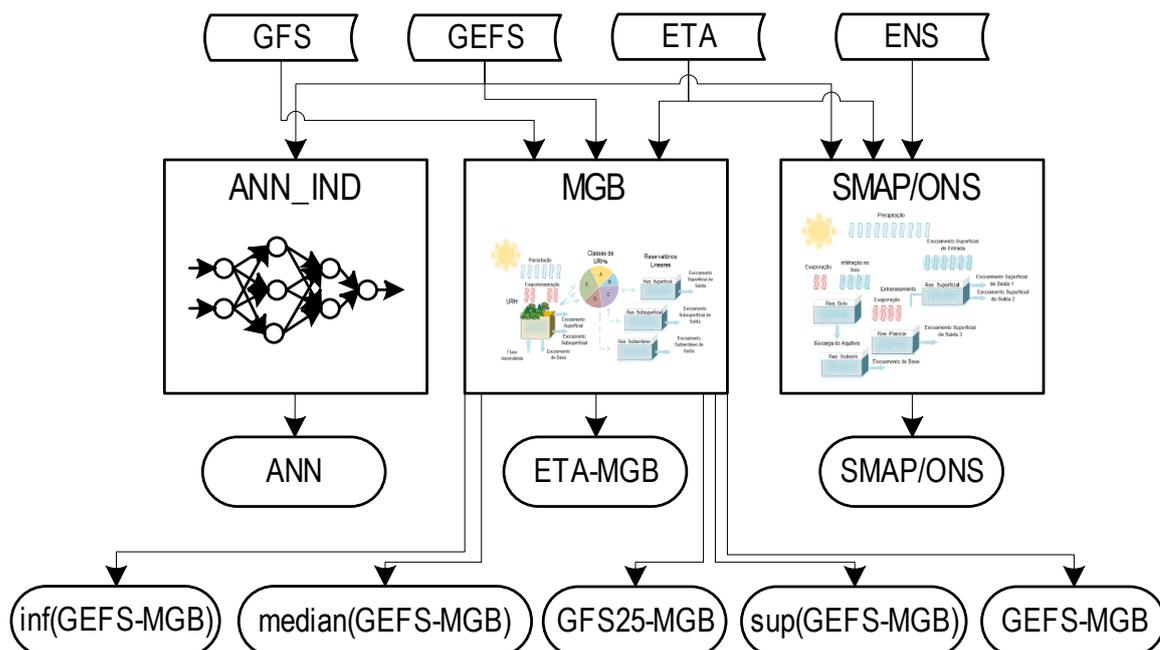


Figura 2 - Cadeias chuva-vazão compostas pela combinação dos modelos GFS, GEFS, ETA e ENS com o SMAP/ONS, o MGB e as ANNs.

### 2.3.5. PONDERAÇÃO BAYESIANA DE MODELOS APLICADA À PREVISÃO DE VAZÕES

#### 2.3.5.1. Algoritmo Expectativa-Maximização

A escolha de um único modelo predictor não leva em consideração as incertezas inerentes à estrutura do modelo [50] e às variáveis predictoras envolvidas no processo. A primeira fonte de incertezas, que se origina do processo de modelagem do fenômeno estudado, pode ter sua intensidade reduzida mediante a combinação das previsões numéricas realizadas por um conjunto de modelos com estruturas distintas [83]. As desvantagens de não considerar a incerteza do modelo foram reconhecidas por muitos autores, mas pouco progresso foi feito até que novos desenvolvimentos teóricos e computacionais viabilizaram a implementação de técnicas de combinação de resultados [49]. BMA [84] é um método estatístico que utiliza estimativas das distribuições de probabilidade *a posteriori* dos modelos de um conjunto para o cálculo de uma média ponderada. A aplicação da BMA neste estudo se justifica pela eficiência e simplicidade da metodologia, que depende basicamente do histórico de vazões observada e vazões previstas, bem como pela necessidade de considerar as incertezas envolvidas. Detalhes sobre a teoria que fundamenta a BMA podem ser consultados em [85].

Os pesos que ponderam as previsões das cadeias chuva-vazão são calculados por meio do algoritmo Expectativa-Maximização (EM) [53], [86]. Nesse método, o problema de estimativa de parâmetros de um modelo estatístico por máxima verossimilhança, *Maximum Likelihood Estimation* [87], é tratado como um problema de falta de dados, em que uma variável  $\hat{z}_{m,t}^{Iter}$ , que será apresentada posteriormente, deve ser estimada. Dessa forma, considere  $Y$  como sendo a variável predita,  $y$  os valores observados para  $Y$  e  $x_m$  as previsões de  $M$  modelos, em que  $m, i = \{1, 2, \dots, M\}$ . A função densidade de probabilidade associada às previsões realizadas pela BMA é expressa em (1).

$$P(Y|y) = \sum_{m=1}^M P(x_m|y) \cdot P_m(Y|x_m, y) \quad (1)$$

A esperança matemática e a variância associadas a essa distribuição são apresentadas em (2) e (3). Na primeira expressão, o valor esperado é calculado por meio da média ponderada das previsões realizadas por cada modelo, onde o termo  $P(x_m|y) = w_m$  atua como peso, interpretado como sendo a probabilidade de um determinado modelo  $x_m$  ser o modelo correto dado  $y$ . Em (3),  $\sigma_m^2$  é a variância associada ao modelo  $m$  com relação aos dados observados  $y$ .

$$E[Y|y] = \sum_{m=1}^M P(x_m|y) \cdot E[P_m(Y|x_m, y)] = \sum_{m=1}^M w_m x_m \quad (2)$$

$$Var[Y|y] = \sum_{m=1}^M w_m \cdot (x_m - \sum_{i=1}^M w_i x_i)^2 + \sum_{m=1}^M w_m \cdot \sigma_m^2 \quad (3)$$

Basicamente, o algoritmo de Expectativa-Maximização alterna entre os passos do tipo E (*Expectation*), em que o valor da variável latente  $\hat{z}_{m,t}^{Iter}$ , cujo papel é indicar o melhor modelo no tempo  $t$ , é calculado, e do tipo M (*Maximization*), onde os valores dos pesos e da variância  $\sigma_m^2$  são atualizados via maximização de uma função *Log-likelihood* aproximada  $l(\theta)$  que depende do conjunto  $\theta = \{w_m, \sigma_m, m = 1, 2, 3, \dots, M\}$ , dado que  $P_m(Y|x_m, y)$  segue uma função Gaussiana  $g(\cdot)$  (para dados normalmente distribuídos), conforme mostra a expressão (4).

$$l(\theta) = \log\left(\sum_{m=1}^M w_m \cdot P_m(Y|x_m, y)\right) \quad (4)$$

$$l(\theta) = \log\left(\sum_{m=1}^M w_m \cdot \sum_{t=1}^T g\left(y_t|x_{m,t}, \sigma_m^{(Iter)}\right)\right)$$

Os passos E e M do algoritmo proposto em [53], [86] são reproduzidos aqui nas expressões matemáticas (5) e (6):

**Expectativa:** a variável latente é calculada para  $m = 1, 2, \dots, M$  e  $t = 1, 2, \dots, T$ .

$$\hat{z}_{m,t}^{Iter} = \frac{g(y_t | x_{m,t}, \sigma_m^{(Iter-1)})}{\sum_{m=1}^M g(y_t | x_{m,t}, \sigma_m^{(Iter-1)})} \quad (5)$$

**Maximização:** utilizando os valores obtidos para  $\hat{z}_{m,t}^{Iter}$ ,  $m = 1, 2, \dots, M$  e  $t = 1, 2, \dots, T$ , os pesos  $w_m^{Iter}$  e variâncias  $\sigma_m^{2(Iter)}$  associados aos modelos são atualizados.

$$w_m^{Iter} = \frac{1}{T} \sum_{t=1}^T \hat{z}_{m,t}^{Iter}, \quad \sigma_m^{2(Iter)} = \frac{\sum_{t=1}^T \hat{z}_{m,t}^{Iter} \cdot (y_t - x_{m,t})^2}{\sum_{t=1}^T \hat{z}_{m,t}^{Iter}} \quad (6)$$

Em seguida, a *Log-likelihood* também é calculada. Caso  $l(\theta^{Iter}) - l(\theta^{Iter-1})$  seja maior que um valor pré-estabelecido, os passos E e M devem ser executados novamente, caso contrário, o processo iterativo finaliza.

### 2.3.5.2. Pré-seleção de Modelos via *Occam's Razor*

Em um esquema de competição entre modelos, a avaliação de cada participante é feita com base na capacidade individualizada de prever o evento alvo. Modelos com desempenho relativo inferior, isto é, cujas previsões são bem menos acuradas que aquelas feitas pelo melhor modelo, devem ser descartados segundo o princípio filosófico *Occam's Razor* discutido por [49] e [50]. Tal princípio prega a simplificação da resolução de um problema por meio da escolha da hipótese mais simples que foi formulada a partir de um conjunto de evidências. Para o caso do nosso problema, isso é traduzido matematicamente da seguinte forma:  $M_k \in \mathcal{H}$  se  $\frac{\max(P(y|M_1), \dots, P(y|M_{K-1}), P(y|M_K))}{P(y|M_k)} \leq C$ , para  $k = 1, \dots, K$ . Onde  $M_k$  é o  $k$ -ésimo modelo,  $\mathcal{H}$  é o conjunto de modelos com desempenho aceitável segundo a restrição estipulada,  $y$  são valores observados da variável de interesse,  $C$  é uma constante e  $P(y|M_k)$  é a probabilidade de se obter  $y$  dado o modelo  $M_k$ .

Em prol do nosso objetivo final, que é o de compor um *ensemble* de previsões de vazões, *Occam's Razor* é utilizado para descartar os modelos com desempenho considerado inadequado.

### 2.3.5.3. Framework Proposto

O *framework* de procedimentos adotados para a composição de um cenário determinístico de vazões via BMA é apresentado nas Figuras 3 e 4. Na primeira etapa, Figura 3, as vazões previstas pelas cadeias chuva-vazão são pré-processadas. Cada um dos arquivos gerados por cadeia, assim como o QObs, tem seu conteúdo assimilado para a composição de um arquivo de entrada por aproveitamento. As séries temporais de vazões observadas e previstas passam por um processo de transformação, utilizando *Box-Cox transformation* [88], que objetiva gerar novos dados distribuídos normalmente. Em seguida, inicia-se o processo de cálculo de pesos utilizando o algoritmo *Expectation-Maximization*, cujos detalhes já foram apresentados na Seção 2.3.5.1. A quantidade de dias do histórico que são empregados na computação dos pesos pode ser de até 120 dias. Com os pesos já definidos, *Occam's Razor* é aplicado, atuando como um filtro que seleciona os modelos com melhor desempenho dentre aqueles do grupo inicial. Por fim, os pesos associados aos modelos que continuam no *ensemble* são normalizados e aplicados ao conjunto de previsões feitas no dia atual para um horizonte temporal de previsão de 11 dias, conforme mostra o exemplo da Figura 4, que adota uma quinta-feira como dia em que os pesos são calculados.

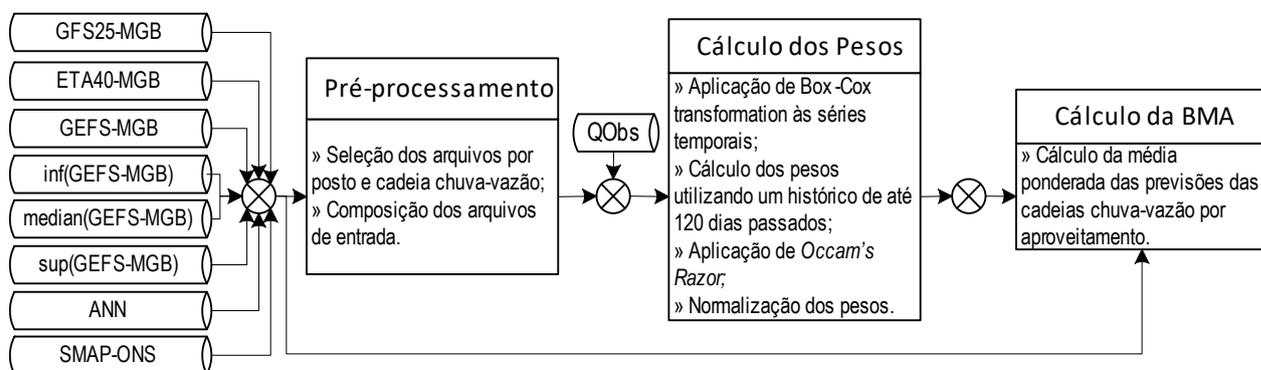


Figura 3 - Fluxograma do procedimento adotado para o cálculo da BMA.

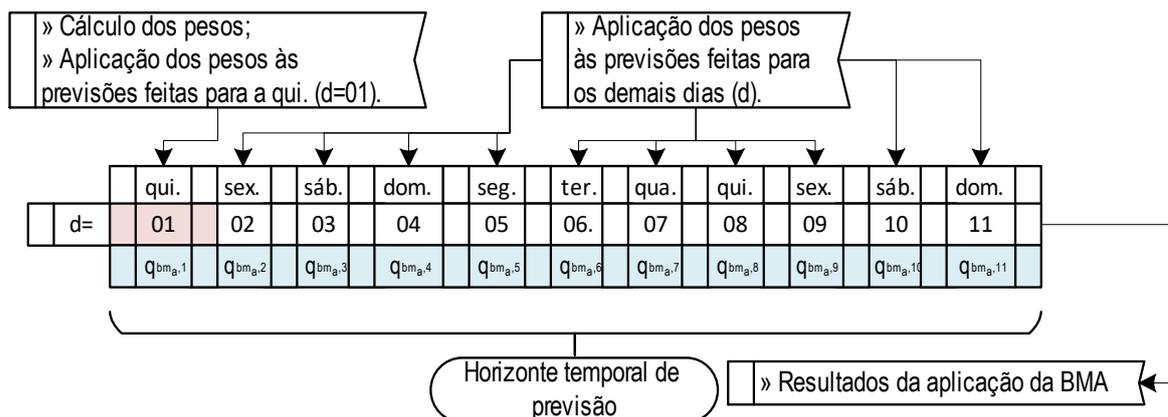


Figura 4 - Exemplo da aplicação dos pesos às previsões feitas em uma quinta-feira.

### 2.3.5.4. Simulação de *Backtest* e Métricas de Avaliação

Para o caso específico dos resultados obtidos via *backtest*, que são numerosas execuções retroativas realizadas para a avaliação do desempenho da BMA ao longo de um período, os pesos calculados às quintas-feiras são reutilizados ao longo da semana (de sexta-feira a quarta-feira), conforme mostra a Figura 5. Essa solução foi adotada a fim de reduzir o tempo necessário para a computação dos pesos associados aos 139 reservatórios e hidrelétricas do SIN. As previsões feitas pelas cadeias chuva-vazão e pela BMA no período de *backtest* foram avaliadas levando em consideração cada um dos dias do horizonte temporal de previsão. Para isso, os dados de cada modelo foram segregados de forma similar ao exemplo apresentado na Figura 6, em que cada

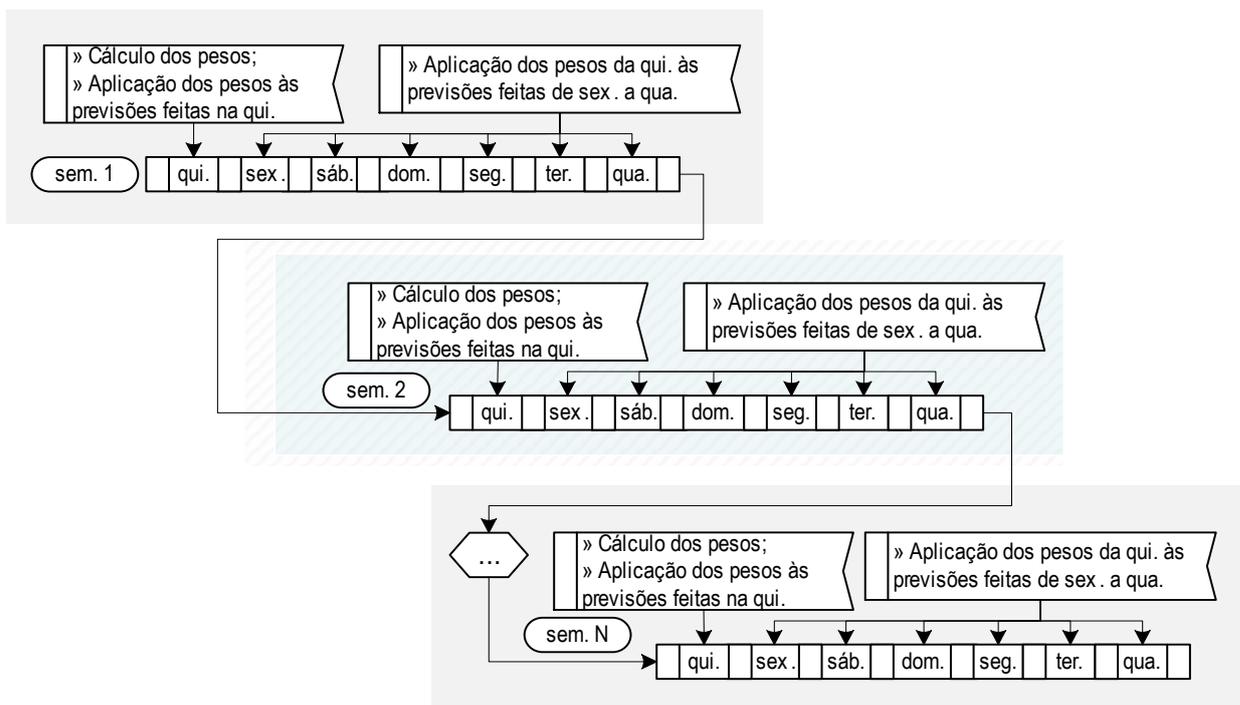


Figura 5 - Fluxograma do procedimento adotado para o cálculo da BMA via *backtest*.

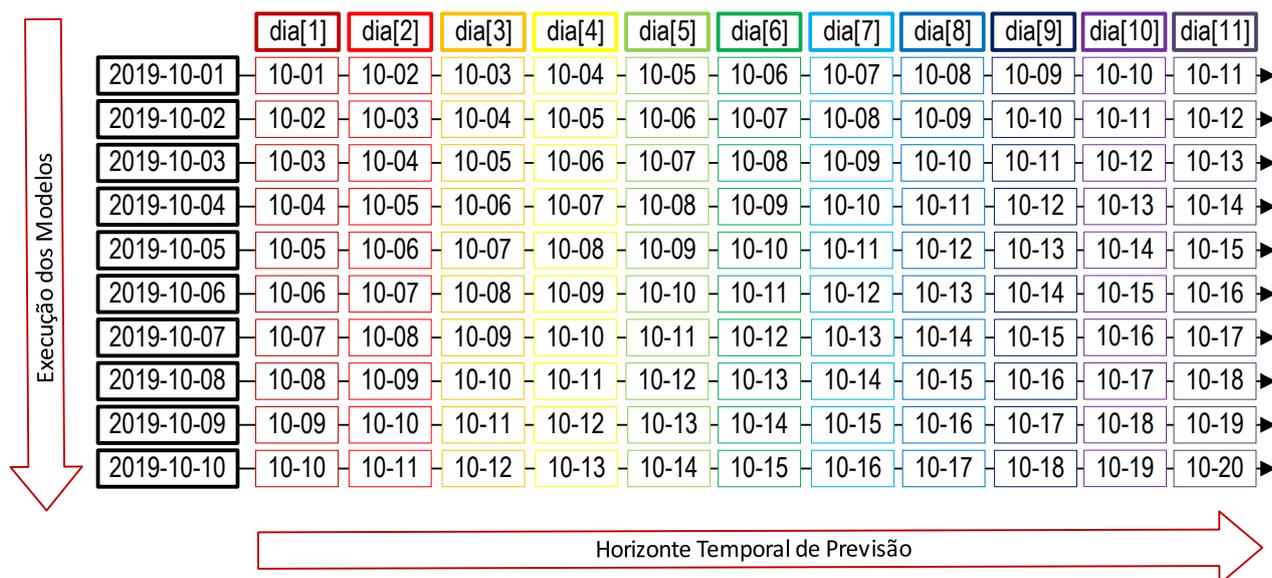


Figura 6 - Segregação das previsões feitas por uma cadeia chuva-vazão de acordo com os dias do horizonte temporal de previsão (dia[1], dia[2], ..., dia[11]). Na imagem, é exemplificado como os resultados das execuções (realizadas de 2019-10-01 a 2019-10-10 no exemplo) geram 11 grupos de dados.

coluna da tabela de previsões (*i.e.*, dia[1], dia[2], ..., dia[11]) define um conjunto a ser avaliado separadamente. Esse procedimento foi adotado em função do interesse em verificar como a acurácia e eficiência das previsões se altera ao longo do horizonte temporal de previsão.

Os conjuntos de dados definidos por dia do horizonte temporal de previsão (dia[1], dia[2], ..., dia[11]) foram avaliadas pelas métricas *Mean Absolute Percentage Error* (MAPE), *Nash-Sutcliffe Efficiency Coefficient* (NSE), Distância Multicritério (DM) e o Teste de Hipóteses de Diebold-Mariano. As definições de cada métrica são apresentadas na Tabela 2.

Tabela 2 - Métricas de avaliação e testes de hipóteses.

Métrica	Detalhes	Equação
<i>Mean Absolute Percentage Error</i> (MAPE)	O MAPE [89], (7), é uma métrica que mede a acurácia ( <i>i.e.</i> , proximidade entre o valor previsto e o valor real) por meio do erro absoluto normalizado médio de um conjunto de previsões. O valor calculado para o MAPE pode variar entre 0 e $\infty$ . Sua interpretação é feita de acordo com intervalos pré-definidos na literatura [89]. Valores entre 0 (0%) e 0,1 (10%) indicam elevada acurácia; valores entre 0,1 (10%) e 0,2 (20%) indicam boa acurácia; valores entre 0,2 (20%) e 0,5 (50%) indicam acurácia razoável; e valores superiores a 0,5 (50%) indicam fraca acurácia.	$MAPE = \frac{1}{T} \sum_{t=1}^T \left  \frac{x_{m,t} - y_t}{y_t} \right  \quad (7)$ <p>Onde <math>x_{m,t}</math> é a previsão feita pelo modelo <math>m</math> no tempo <math>t</math> (<math>1, 2, \dots, T</math>) e <math>y_t</math> é o valor observado real.</p>

Nash-  
Sutcliffe  
Efficiency  
Coefficient  
(NSE)

O NSE [90], (8), é uma métrica bastante utilizada na avaliação da eficiência de modelos preditivos de vazão. Ele mede a razão entre a variância residual (*i.e.*, soma dos quadrados dos resíduos) e a variância do conjunto de dados reais observados (*i.e.*, soma dos quadrados totais) subtraída de 1. O valor calculado para o NSE pode variar entre 1 e  $-\infty$ . Assim como é feito para o MAPE, a interpretação do NSE também é baseada em intervalos pré-definidos na literatura [91]. Valores superiores a 0,75 indicam que o modelo apresenta uma eficiência muito boa; valores entre 0,65 e 0,75 indicam uma eficiência boa; valores entre 0,5 e 0,65 indicam eficiência satisfatória; e valores inferiores a 0,5 indicam eficiência insatisfatória. Ademais, valores inferiores a zero também indicam que a média do conjunto de valores reais observados gera uma previsão melhor do que aquela realizada pelo modelo avaliado.

$$\text{NSE} = 1 - \frac{\sum_{t=1}^T (x_{m,t} - y_t)^2}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (8)$$

Onde  $x_{m,t}$  é a previsão feita pelo modelo  $m$  no tempo  $t$  ( $1, 2, \dots, T$ ),  $y_t$  é o valor observado real e  $\bar{y}$  é a média do conjunto de observações

Distância  
Multicritério  
(DM)

A DM [92], (9), é a métrica utilizada oficialmente pelo ONS para avaliar previsões de vazão desde 2010. Ela é definida como a distância euclidiana  $d$  calculada entre dois pontos  $p1 = (x_{p1}, y_{p1})$  e  $p2 = (x_{p2}, y_{p2})$ ,

$$d = \sqrt{(x_{p1} - x_{p2})^2 + (y_{p1} - y_{p2})^2}, \quad \text{onde o}$$

primeiro ponto tem como coordenadas os valores perfeitos de MAPE e NSE (*i.e.*,  $x_{p1} = 0$  e  $y_{p1} = 1$ , respectivamente) e o segundo tem como coordenadas os valores reais calculados  $x_{p2} = \text{MAPE}$  e  $y_{p2} = \text{NSE}$ . A DM pode variar no intervalo fechado definido por  $[0, \infty]$ , sendo que quanto maior for seu valor, pior é o desempenho do modelo preditor avaliado. Dessa forma, o ideal é que ela assume um valor próximo de zero. Ademais, é importante frisar que a DM é um índice robusto por combinar métricas com enfoques distintos.

$$\text{DM} = \sqrt{\text{MAPE}^2 + (1 - \text{NSE})^2} \quad (9)$$

Teste de  
Hipóteses de  
Diebold-  
Mariano

O Teste de Hipóteses de Diebold-Mariano [93] é um teste amplamente utilizado para a comparação da acurácia preditiva de duas séries temporais A e B através dos resíduos calculados com relação aos valores observados da variável predita (*i.e.*,  $e_{A,t}$  e  $e_{B,t}$ ). Cada série temporal está associada a uma função de perda  $\text{loss}(\cdot)$  que tipicamente é definida como sendo o erro absoluto ou o erro quadrático ao longo do tempo:  $\text{loss}(e_{A,t})$  e  $\text{loss}(e_{B,t})$ . A diferença entre as funções é denominada de função diferencial de perda:  $d_t = \text{loss}(e_{A,t}) - \text{loss}(e_{B,t})$ . Na versão original do teste (10), se a esperança matemática de  $d_t$  for zero  $E(d_t) = 0$  (*i.e.*, hipótese nula  $H_0$ ), diz-se que as séries temporais avaliadas possuem o mesmo nível de acurácia, caso contrário as acurácias das séries divergem  $E(d_t) \neq 0$  (*i.e.*, hipótese alternativa  $H_a$ ). Já

Hipóteses originais:

$$\begin{aligned} H_0: E(d_t) &= 0 \\ H_a: E(d_t) &\neq 0 \\ p\text{-value} &= 2 \times [1 - \text{FDA}(\text{DMT}_{\text{calc}})] \end{aligned} \quad (10)$$

Hipóteses modificadas I:

$$\begin{aligned} H_0: E(d_t) &\geq 0 \\ H_a: E(d_t) &< 0 \\ H_a: \text{a série A é mais acurada que} & \text{a série B.} \\ p\text{-value} &= \text{FDA}(\text{DMT}_{\text{calc}}) \end{aligned} \quad (11)$$

Hipóteses modificadas II:

$$\begin{aligned} H_0: E(d_t) &\leq 0 \\ H_a: E(d_t) &> 0 \\ H_a: \text{a série B é mais acurada que} & \text{a série A.} \\ p\text{-value} &= [1 - \text{FDA}(\text{DMT}_{\text{calc}})] \end{aligned} \quad (12)$$

nas versões modificadas I e II do teste (11)(12), as hipóteses são alteradas para que seja possível determinar se a série A é mais acurada que a série B, ou se a série B é mais acurada que a série A, respectivamente. A avaliação dos resultados é feita através da análise do *p-value* calculado utilizando o valor da estatística  $DMT_{calc}$  expressa em (13). Valores de *p-value* inferiores ao nível de significância do teste ( $\alpha$ ) indicam que há evidências suficientes para a rejeição da  $H_0$  e aceitação da  $H_a$ , enquanto valores de *p-value* superiores a  $\alpha$  indicam que não há evidências suficientes para a rejeição da  $H_0$  e aceitação da  $H_a$ .

Estatística de Diebold-Mariano:

$$DMT_{calc} = \frac{\bar{d}}{\sqrt{\frac{\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k}{n}}} \quad (13)$$

Onde FDA é a função densidade de probabilidade acumulada da estatística  $DMT$ ;  $h$  é o horizonte temporal de previsão;  $\gamma_k$  é a autocovariância de lag  $k$  da função  $d$ ;  $n$  é a quantidade de dados em cada série temporal; e  $\bar{d}$  é a média da função diferencial de perda.

A autora desta tese de doutorado foi responsável por toda a implementação da BMA, pela condução das simulações de *backtest*, e pela análise detalhada dos resultados obtidos ao longo do estudo. Todos esses processos foram desenvolvidos utilizando a linguagem de programação R.

## 2.4. RESULTADOS E DISCUSSÃO

### 2.4.1. PERFORMANCE GERAL DO *ENSEMBLE*

O *framework* proposto na Seção 2.3.5.3 foi testado via simulações de *backtest* considerando o período que vai de agosto de 2019 a setembro de 2020. Nesse decurso, foram realizadas execuções diárias com horizonte temporal de previsão de 11 dias para as vazões afluentes de todos os reservatórios e hidrelétricas destacados na Figura 1. Por questão de concisão, os resultados foram avaliados de forma conjunta através de mapas e boxplots gerados a partir das métricas selecionadas. Entretanto, para facilitar o entendimento da metodologia através de um exemplo, a Figura 7 apresenta as médias das previsões feitas ao longo do tempo e os pesos aplicados a cada membro do *ensemble* para a formação da BMA associada à hidrelétrica Água Vermelha. Os resultados obtidos nesse exemplo indicam que em determinados trechos do gráfico (entre os meses de agosto e dezembro de 2019, por exemplo), o SMAP/ONS e a ANN recebem pesos superiores àqueles atribuídos às demais cadeias. Isso ocorre devido a aplicação do princípio de *Occam's Razor*, que é responsável por descartar os membros com desempenho relativo baixo (*i.e.*, zerar seus respectivos pesos), resultando em um refinamento do conjunto de modelos que permanecem ativos.

De fato, a seleção dos membros com bom desempenho é capaz de aumentar a acurácia do *ensemble* [94] visto que a ação conjunta dos membros com mau desempenho, apesar de ponderados por pesos de menor intensidade, afeta a BMA. Ao descartar os membros com performance inferior, o *ensemble* final de cadeias chuva-vazão é menor que o conjunto original, resultando na intensificação dos pesos atribuídos aos membros que não foram eliminados. Dessa forma, cadeias chuva-vazão tais como a ANN e o SMAP/ONS acabam sendo mais valorizadas por meio de pesos maiores. Além disso, nota-se que quando vários membros apresentam performance boa, os pesos tendem a ser mais próximos, sem atribuição de pesos muito elevados a um modelo específico (*e.g.*, entre os meses de fevereiro e maio de 2020). Esse comportamento observado ao longo do eixo temporal ilustra o fato das cadeias chuva-vazão apresentarem uma performance variável que pode ser decorrente de vários fatores, como, por exemplo, a incapacidade do modelo chuva-vazão em simular adequadamente vazões em determinados níveis (*e.g.*, vazões muito baixas

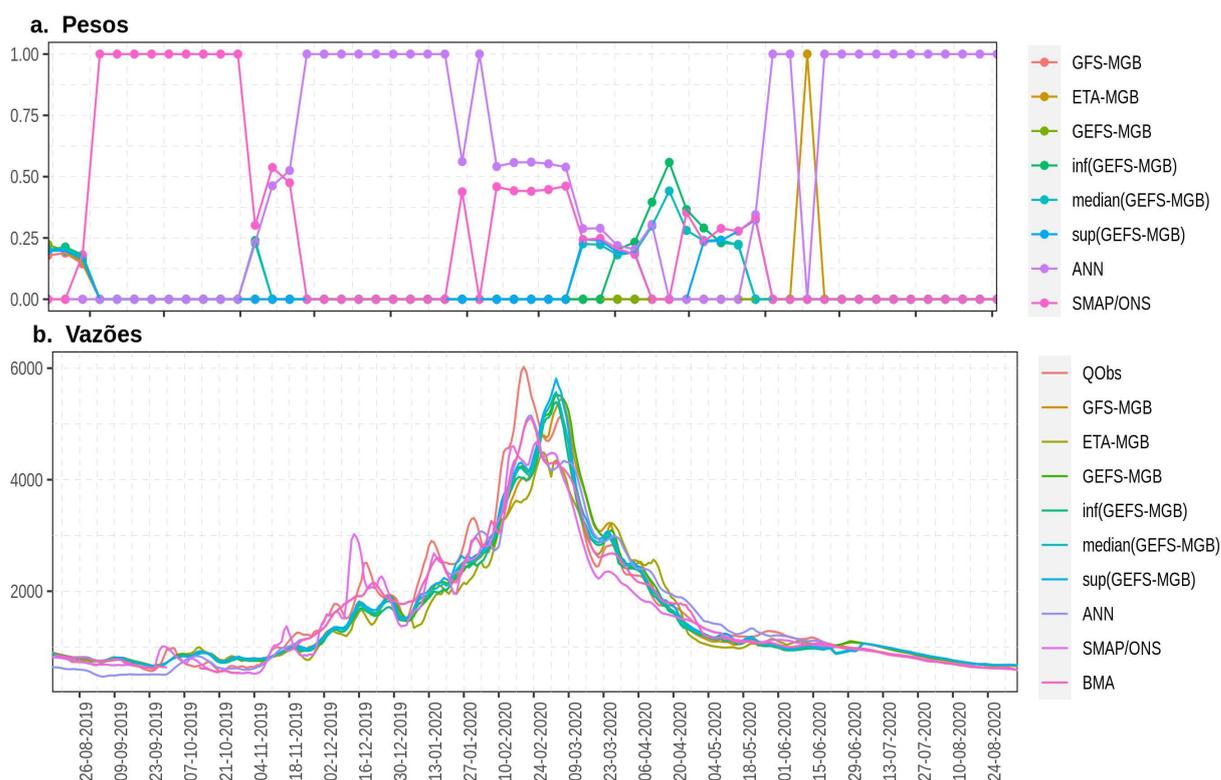


Figura 7 - Vazões previstas pelas cadeias chuva-vazão e pesos aplicados para a formação da BMA associada às vazões afluentes da hidrelétrica Água Vermelha. A primeira imagem mostra os membros do *ensemble* (GFS-MGB, ETA-MGB, GEFS-MGB, inf(GEFS-MGB), median(GEFS-MGB), sup(GEFS-MGB), ANN, SMAP/ONS), o cenário determinístico de vazões computado via BMA e as vazões observadas *in situ* (QObs) para o período de agosto de 2019 a setembro de 2020. A DM calculada com as previsões da BMA é de 0,084, inferior às DMs calculadas com as previsões das outras cadeias chuva-vazão.

ou muito altas), inconsistências nos dados de vazão/precipitação observada ou até por influência de previsões de precipitação com baixa acurácia.

As Figuras 8 e 9 apresentam a performance das cadeias chuva-vazão e BMA em termos de MAPE, NSE e DM. A Figura 8 contempla os resultados associados aos 67 reservatórios e hidrelétricas cujas vazões são simuladas pelo modelo SMAP/ONS, localizados majoritariamente no Sul, Centro-Oeste e Sudeste do Brasil, enquanto a Figura 9 revela os resultados associados aos 72 reservatórios e hidrelétricas sem SMAP/ONS, concentrados predominantemente nas regiões Norte e Nordeste do Brasil. As métricas foram computadas individualmente para cada um dos aproveitamentos do SIN utilizando os resultados das execuções realizadas na simulação de *backtest*. A fim de determinar o desempenho dos modelos com o aumento da antecedência das previsões, as métricas MAPE, NSE e DM são calculadas utilizando dados das previsões feitas para dia[1], dia[7] e dia[11] do horizonte temporal de previsão, conforme o esquema apresentado na Seção 2.3.5.4.

A Figura 8 mostra que as previsões feitas para o dia[1] pelas cadeias chuva-vazão dependentes do MGB e de Redes Neurais (ANN) apresentam desempenhos similares, com MAPE médio entre 0,19 e 0,25, o que significa que em média a acurácia é razoável. No caso do SMAP/ONS e da BMA, o MAPE médio é ainda menor e igual a 0,16 e 0,15, respectivamente; o que corresponde a um desempenho superior e acurácia boa. Entretanto, quando são avaliados os resultados dos dias 7 e 11, verifica-se que a performance da BMA e das outras cadeias piora, resultando na redução generalizada da acurácia dos modelos e do limite superior dos boxplots em geral. Em termos de média, todas as cadeias possuem acurácia razoável, exceto a cadeia sup(GEFS-MGB) com acurácia fraca e MAPE médio superior a 0,5 no dia[11]. No caso específico da BMA, observa-se uma resposta similar a dos modelos com as melhores métricas, com MAPE médio de 0,24 no dia[7] e 0,30 no dia[11], mas ainda assim maiores ou iguais àqueles calculados para a cadeia SMAP/ONS.

O declínio no desempenho das cadeias chuva-vazão também está associado ao aumento da incerteza nas previsões de precipitação, conforme o horizonte temporal de previsão se estende. Nesta questão, a cadeia SMAP/ONS possui uma vantagem relevante sobre os outros membros do *ensemble*. Ela recebe como *input* o resultado da combinação de três conjuntos de dados submetidos previamente a um processo de correção de viés (*i.e.*, dados do ETA 40, GEFS e ENS) [39] que visa aprimorar a estimativa do total de chuva incidente em cada uma das sub-bacias modeladas. Dentre os modelos analisados, o MGB é o mais afetado pela incerteza relacionada a precipitação, e isso se deve principalmente a ele ser um modelo distribuído (*i.e.*, que considera a variabilidade

---

espacial da bacia) e, portanto, sensível a erros espaciais nas previsões de chuva. Além disso, as previsões de precipitação que alimentam o MGB não passam por um processo de ajuste, ou correção de viés, como o adotado no caso do SMAP/ONS. Dessa forma, se o sistema numérico de previsão tempo apresentar uma tendência de sobrestimar ou subestimar a precipitação, a chuva enviesada poderá afetar a performance da cadeia chuva-vazão.

Com relação ao coeficiente de eficiência, o valor médio dos NSEs calculado com as previsões feitas para o dia[1] pela BMA é de aproximadamente 0,77 (*i.e.*, eficiência média muito boa). Os outros modelos apresentam eficiência boa, com valores médios de NSE abaixo de 0,65, com exceção da ANN cujo NSE médio é 0,74. Nos dias 7 e 11, a eficiência das previsões decaiu de forma generalizada, mas ainda assim, a cadeia BMA apresenta os maiores valores de NSE em todos os casos (*i.e.*, é mais eficiente que os membros do *ensemble*). Enquanto isso, outras cadeias como ETA-MGB e sup(GEFS-MGB) apresentam uma queda de desempenho mais acentuada que as demais por influência de reservatórios e hidrelétricas em que a eficiência do modelo é muito baixa, gerando *outliers* que ultrapassam -2. Com relação a distribuição dos quartis, nota-se que o limite inferior dos boxplots e os *outliers* de todos os modelos avança em direção a região negativa quando a antecedência com que as previsões são feitas aumenta, indicando que para o caso de alguns aproveitamentos os modelos passam a apresentar um desempenho pior do que a simples média dos valores observados de vazão.

A última métrica analisada, DM, conclui que a BMA apresenta em média (*i.e.*, quando todos os aproveitamentos são avaliados conjuntamente) resultados melhores que aqueles obtidos para as demais cadeias chuva-vazão em todos os casos (dia[1], dia[7] e dia[11]) apesar da redução da performance de suas previsões quando a antecedência das previsões aumenta. Isso mostra que quando o MAPE e o NSE são analisados conjuntamente via DM, a aplicação da BMA para a geração de previsões de vazão para os aproveitamentos localizados majoritariamente no Sul, Centro-Oeste e Sudeste do Brasil se destaca como a melhor alternativa.

---

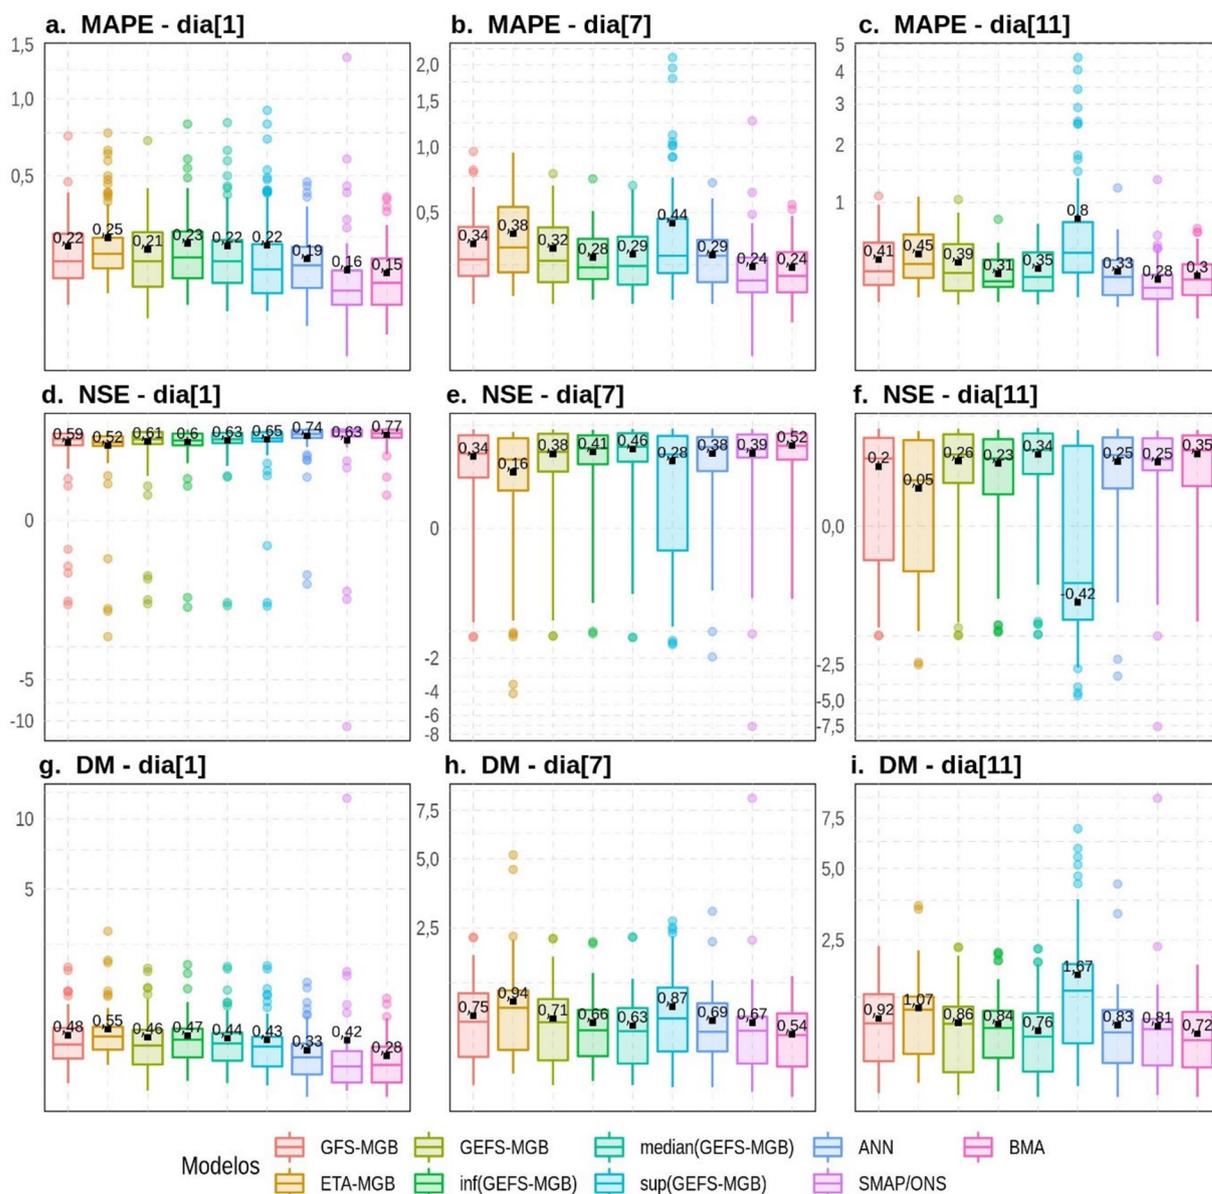


Figura 8 - Boxplot dos MAPEs, NSEs e DMs calculados para as vazões afluentes aos reservatórios e hidrelétricas do SIN (contemplados pelo modelo SMAP/ONS) utilizando as previsões feitas com 1, 7 e 11 dias de antecedência. Na composição dos gráficos, foram utilizados os dados obtidos com as execuções retroativas durante o período de *backtest*. Ao todo, foram avaliadas as previsões de vazão realizadas para 67 aproveitamentos. Os boxplots das imagens apresentam as distribuições dos MAPEs, NSEs e DMs em quartis para cada uma das cadeias chuva-vazão. A linha horizontal no interior de cada caixa representa a mediana, enquanto as linhas delimitadoras inferior e superior representam os quartis  $Q_1$  e  $Q_3$ , respectivamente. O limite superior do boxplot é definido por  $Q_3 + 1,5(Q_3 - Q_1)$  e o inferior por  $Q_3 - 1,5(Q_3 - Q_1)$ . Os pontos fora das caixas representam os *outliers*, enquanto o marcador em preto representa a média. A escala do eixo  $y$  de cada gráfico passou por um processo de transformação usando a função raiz cúbica  $\sqrt[3]{y}$  para a melhor visualização dos resultados.

No caso dos reservatórios e hidrelétricas cujas vazões não são contempladas pelo SMAP/ONS, a BMA apresenta boa acurácia e MAPE médio de 0,19 em previsões feitas para o dia[1], enquanto as demais cadeias chuva-vazão apresentam acurácia razoável, com médias entre 0,20 e 0,24, conforme mostra a Figura 9. Entretanto, no caso das previsões feitas para os dias 7 e 11, a acurácia de todos os modelos decai, atingindo valores médios de MAPE superiores a 0,28. Ao comparar os membros individuais do *ensemble* à BMA, observa-se que as cadeias inf(GEFS-MGB) e ANN apresentam acurácia superior nos dias 7 e 11.

Com relação ao coeficiente de eficiência, o valor médio dos NSEs calculados com as previsões da BMA para o dia[1] é de aproximadamente 0,73 (*i.e.*, eficiência média muito boa). Os outros modelos apresentam eficiência boa ou muito boa, com valores médios de NSE entre a 0,67 e 0,73. No entanto, quando a antecedência com que as previsões são feitas aumenta, a eficiência decai de forma generalizada e os limites inferiores do boxplots avançam para a região negativa, mas ainda assim, a BMA apresenta os maiores valores médios de NSE nos dias 1 e 7. Ademais, observa-se que os membros GEFS-MGB e median(GEFS-MGB) ultrapassam a BMA em termos de eficiência no dia 11.

Ao avaliar os dados utilizando a métrica DM (que considera o MAPE e o NSE conjuntamente), nota-se que a BMA está associada aos menores valores médios de DM para as previsões dos dias 1 e 7. No caso dia[11], as cadeias inf(GEFS-MGB) e median(GEFS-MGB) superam a BMA em desempenho. Dessa forma, quando o MAPE e o NSE são analisados conjuntamente via DM, a aplicação da BMA para a geração de previsões de vazão para os postos fluviométricos do Norte e Nordeste do Brasil se destaca como a melhor alternativa.

Em suma, os resultados apresentados nas Figuras 8 e 9 indicam que, segundo a métrica DM, a BMA apresenta *em média* o melhor desempenho para: a) os reservatórios e hidrelétricas em sub-bacias simuladas pelo SMAP/ONS, localizados predominantemente nas regiões Centro-Oeste, Sudeste e Sul do Brasil, nos dias 1, 7 e 11; e b) os reservatórios e hidrelétricas situadas em sub-bacias não simuladas pelo SMAP/ONS, situados majoritariamente nas Regiões Norte e Nordeste do Brasil, nos dias 1 e 7. Os resultados obtidos nesse trabalho estão em concordância com outros estudos [16], [51], [53] que mostram que a aplicação de BMA é capaz de gerar previsões melhores ou comparáveis às previsões dos melhores modelos individuais de um *ensemble*.

Nesse processo de previsão via BMA, é importante enfatizar que as previsões feitas para os dias 1, 2, 3, ..., 11 são ponderadas pelo mesmo conjunto de pesos. Conseqüentemente, não se faz distinção entre os pesos aplicados no início e no fim do horizonte de previsão de uma mesma cadeia chuva-vazão. Essa é uma questão que se mostrou relevante durante a avaliação dos

resultados, visto que algumas cadeias apresentaram um bom desempenho nas previsões feitas com 1 dia de antecedência, mas não conseguem manter a performance relativa com a extensão do horizonte temporal; ou ainda, há casos em que cadeias com desempenho mediano no dia[1] são capazes de realizar previsões relativamente melhores nos dias seguintes. A exemplo disso, destacam-se as Figuras 9 a., b. e c., em que a cadeia inf(GEFS-MGB) não apresentava a melhor acurácia no dia 1, mas foi capaz de ultrapassar a performance dos outros modelos nos dia 7 e 11.

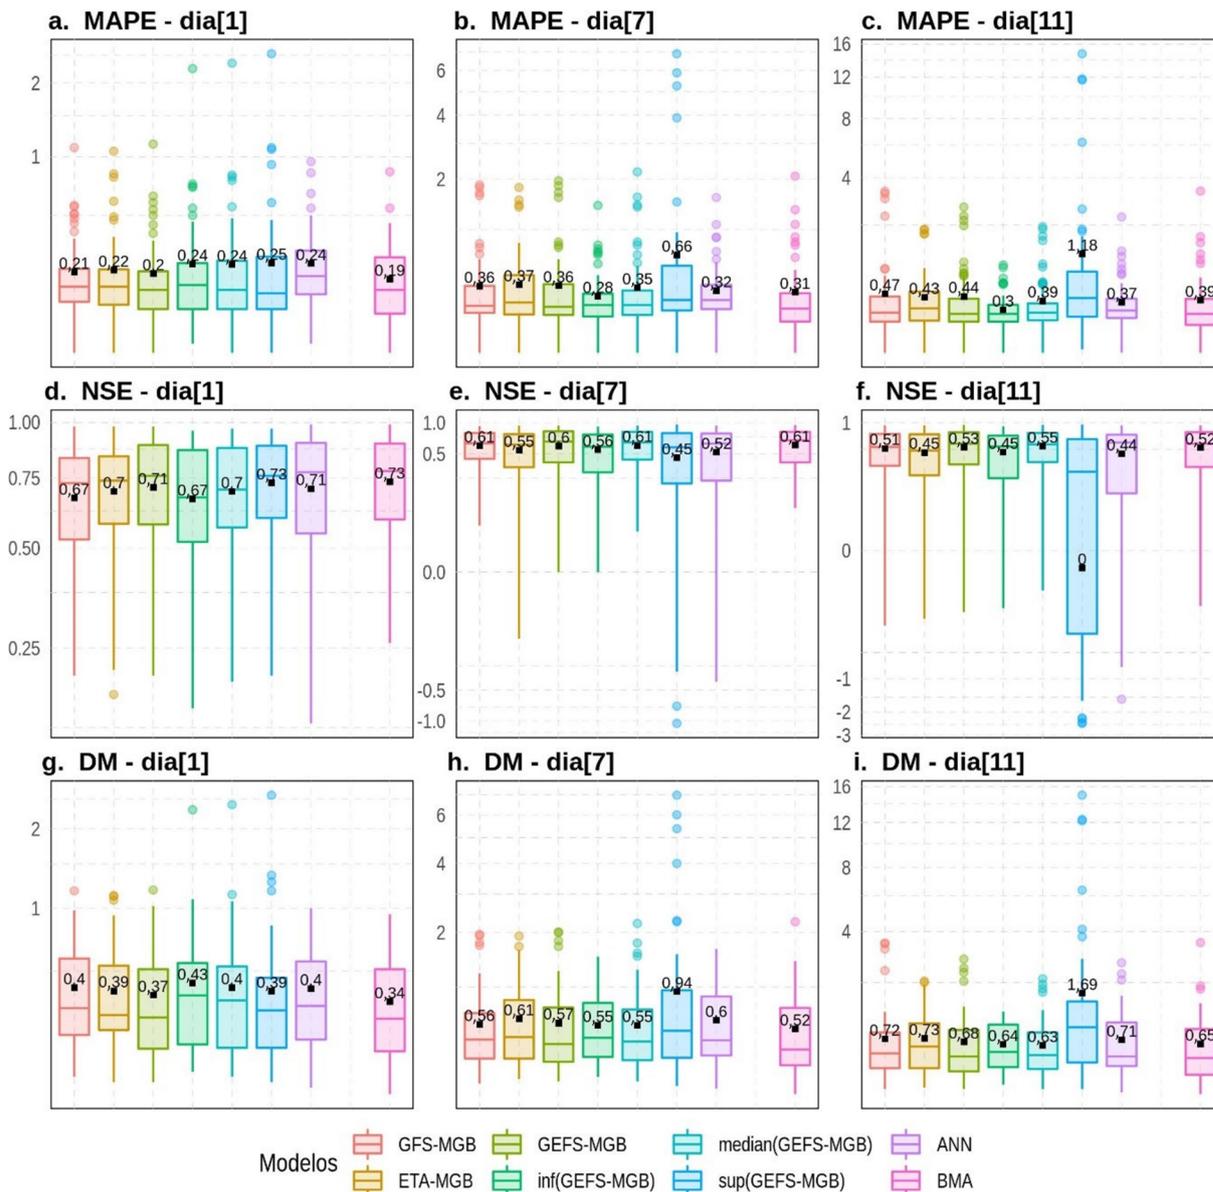


Figura 9 - Boxplot dos MAPEs, NSEs e DMs calculados para as vazões afluentes aos reservatórios e hidrelétricas do SIN (não contemplados pelo modelo SMAP/ONS) utilizando as previsões feitas com 1, 7 e 11 dias de antecedência. Na composição dos gráficos, foram utilizados os dados obtidos com as execuções retroativas durante o período de *backtest*. Ao todo, foram avaliadas as previsões de vazão realizadas para 72 aproveitamentos. A escala do eixo y de cada gráfico passou por um processo de transformação usando a função raiz cúbica  $\sqrt[3]{y}$  para a melhor visualização dos resultados.

Em função desse comportamento, é interessante verificar por meio de trabalhos futuros a aplicação de pesos que diferem com o aumento da antecedência das previsões. Nessa avaliação, 11 conjuntos de pesos seriam calculados para cada um dos reservatórios e hidrelétricas do SIN, e a ponderação Bayesiana de modelos seria computada utilizando um conjunto de pesos específico para cada dia do horizonte temporal de previsão.

#### 2.4.2. PERFORMANCE ESPACIAL DA BMA

Os padrões espaciais dos MAPEs, NSEs e DMs são apresentados na Figura 10 para o caso da BMA. Na imagem constam mapas associadas às previsões feitas para os dias 1, 7 e 11 do horizonte temporal de previsão considerando todos os 139 reservatórios e hidrelétricas. O primeiro mapa, relativo ao dia[1], indica que as previsões feitas pela BMA para os reservatórios e hidrelétricas localizados nas regiões Norte, Nordeste, Centro-Oeste e parte do Sudeste do Brasil apresentam acurácia elevada em diversos aproveitamentos ( $MAPE \leq 0,1$ ), com algumas exceções pontuais ao longo do litoral brasileiro. A região Sudeste, caracterizada por uma alta densidade de aproveitamentos, se destaca entre as demais em função da predominância de cascatas de reservatórios e hidrelétricas cujas vazões são previstas de forma satisfatória pela BMA. Com relação ao Sul, nota-se a predominância de reservatórios e hidrelétricas em que a BMA apresenta acurácia boa ( $0,1 < MAPE \leq 0,2$ ) e razoável ( $0,2 < MAPE \leq 0,5$ ). Essa queda relevante de desempenho do modelo Bayesiano pode ser justificada pela alta volatilidade das vazões observadas nos rios dessa região (*e.g.*, Rio Jacuí em que os picos de vazões costumam ser muito altos na ocorrência de chuvas e difíceis de serem previstos acuradamente), o que acaba afetando o processo de previsão, principalmente durante a estação chuvosa.

Os mapas relativos ao NSE, Figura 10, concordam com aqueles obtidos para o MAPE. Conforme mostra o mapa associado a dia[1], a BMA apresenta eficiência muito boa em vários postos localizados no Norte, Nordeste, Centro-Oeste e Sudeste do Brasil, enquanto postos do litoral brasileiro e a região Sul apresentam eficiência satisfatória ( $0,5 < NSE \leq 0,65$ ) ou insatisfatória ( $NSE \leq 0,5$ ). Quando a antecedência é de 7 ou 11 dias, observa-se a intensificação desse padrão espacial. Apenas postos do Norte, Nordeste, Centro-Oeste e parte do Sudeste continuam apresentando eficiência satisfatória, enquanto no Sul, parte do Sudeste e litoral brasileiro as previsões para a maioria dos postos possuem eficiência insatisfatória. Como mencionado anteriormente, essa degradação da qualidade das previsões costuma ocorrer em bacias hidrográficas com afluentes que apresentam alta variabilidade nas vazões, isto é, bacias que

possuem tempo de concentração pequeno e que respondem rapidamente à precipitação através de picos elevados [95]. Já no caso da métrica DM, o padrão espacial observado para o MAPE e o NSE se repete.

Os resultados da aplicação do Teste de Hipóteses de Diebold-Mariano às séries temporais de vazões previstas pelos membros do ensemble e pela BMA são apresentados na Figura 11. Os aproveitamentos destacados na cor verde são aqueles em que as previsões da BMA são significativamente mais acuradas que as feitas pelo membro concorrente, enquanto os aproveitamentos em vermelho são aqueles em que as previsões da BMA são menos acuradas que as feitas pela cadeia concorrente. Já os aproveitamentos destacados em amarelo são aqueles em que estatisticamente não há diferença entre a acurácia dos modelos concorrentes. Os resultados obtidos com aplicação deste teste indicam que as séries temporais de previsões realizadas pelas cadeias chuva-vazão GFS-MGB, ETA-MGB, GEFS-MGB, inf(GEFS-MGB), sup(GEFS-MGB) e ANN são significativamente menos acuradas que aquelas geradas pela BMA na maioria dos

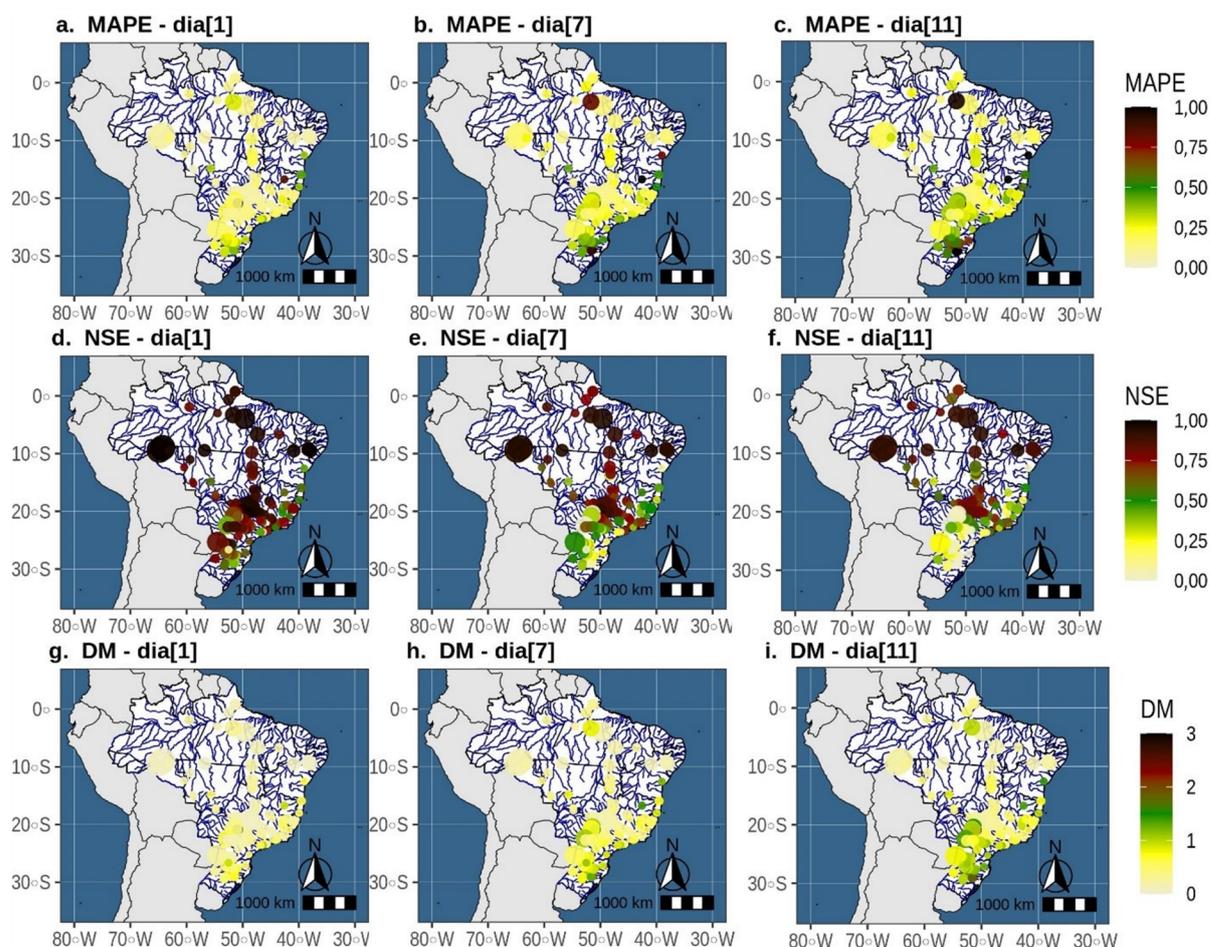


Figura 10 - Padrão espacial de MAPEs, NSEs e DMs das previsões de vazão feitas pela BMA para os dias 1, 7 e 11. Nos mapas, a vazão média de longo termo é utilizada para definir o tamanho do círculo que destaca os reservatórios e hidrelétricas.

aproveitamentos. No caso das cadeias median(GEFS-MGB) e SMAP/ONS observa-se um aumento no total de aproveitamentos em que acurácia dos modelos concorrentes não é significativamente diferente e, também, a ocorrência de alguns casos em que o membro do ensemble testado supera a BMA, principalmente no caso do SMAP/ONS na região Sul, o que reforça os resultados já observados na Figura 8.

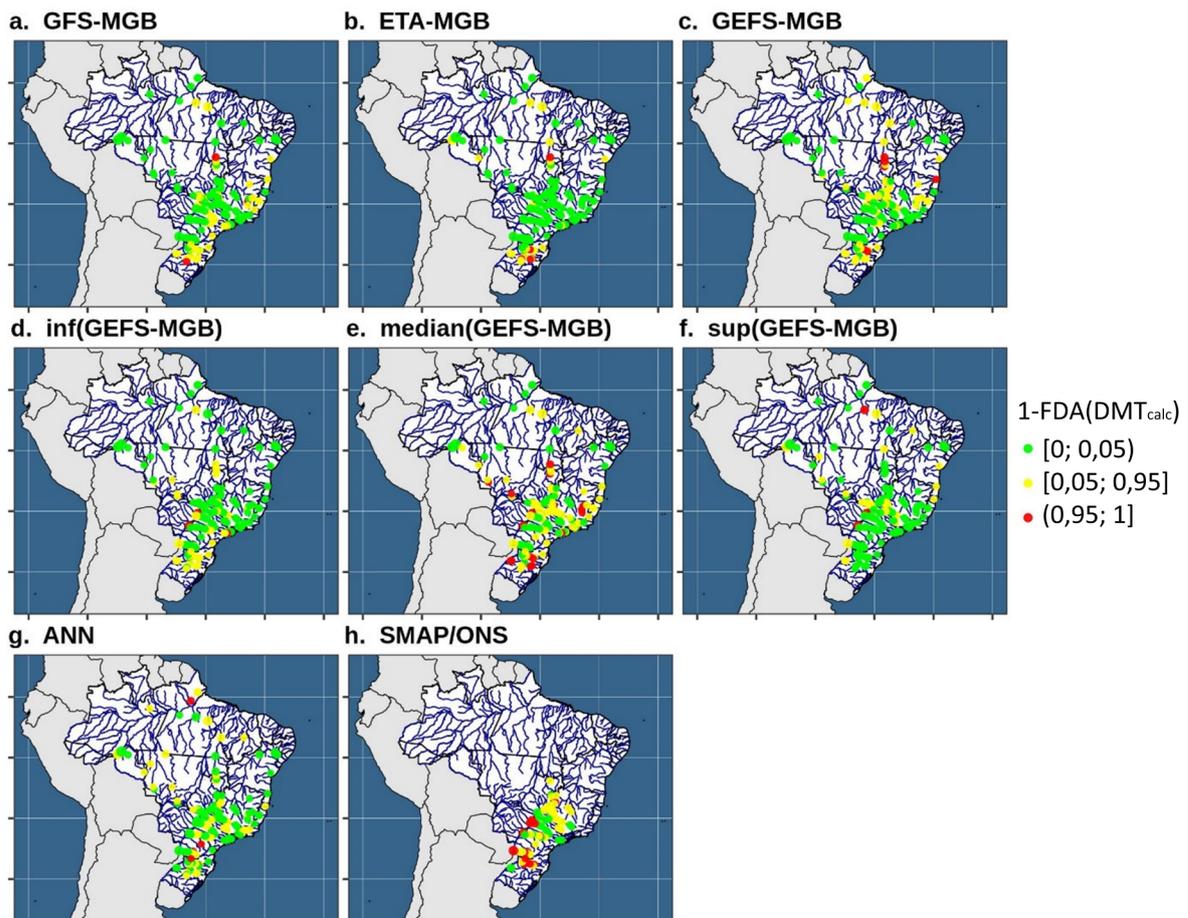


Figura 11 - Padrão espacial de  $[1 - FDA(DMT_{calc})]$  calculado através da aplicação do Teste de Hipóteses de Diebold-Mariano considerando todas as previsões realizadas até 11 dias à frente. Cada mapa apresenta os resultados da comparação entre as previsões feitas por um dos membros do *ensemble* e a BMA. Se  $0 \leq [1 - FDA(DMT_{calc})] < 0,05$ , onde  $[1 - FDA(DMT_{calc})]$  é igual ao *p-value* do teste em (12) dado  $\alpha = 0,05$ , a série temporal de previsões realizadas pela BMA é significativamente mais acurada que a série associada ao membro concorrente; se  $0,05 \leq [1 - FDA(DMT_{calc})] \leq 0,95$ , nenhuma das séries temporais é significativamente mais acurada que outra; e se  $0,95 < [1 - FDA(DMT_{calc})] \leq 1$ , onde  $FDA(DMT_{calc})$  é igual ao *p-value* do teste em (11) dado  $\alpha = 0,05$ , a série temporal de previsões feitas pelo membro do *ensemble* é significativamente mais acurada que a série computada pela BMA.

### 2.4.3. PESOS APLICADOS AOS MEMBROS DO ENSEMBLE

Conforme discutido em seções anteriores, a BMA é o resultado da aplicação de pesos às vazões previstas pelo conjunto de cadeias chuva-vazão GFS-MGB, ETA-MGB, GEFS-MGB, inf(GEFS-MGB), median(GEFS-MGB), sup(GEFS-MGB), ANN e SMAP/ONS. Na abordagem adotada neste estudo, os pesos são recalculados semanalmente conforme as séries históricas de vazões previstas e observadas são atualizadas com novos dados. Isso possibilita que a BMA leve em consideração o comportamento recente dos modelos envolvidos, que é uma característica importante a ser considerada quando existe a possibilidade do desempenho dos modelos variar ao longo do tempo, como ocorre nos períodos seco, chuvoso e de transição entre estações. Além disso, é importante salientar que não se sabe com antecedência exatamente quando esses períodos iniciam e terminam, podendo haver atraso ou adiantamento com relação ao verificado em anos anteriores, fato que justifica o uso de pesos dinâmicos e não conjuntos de pesos estáticos por período.

Essa mudança no comportamento dos modelos, e conseqüentemente na acurácia e eficiência de suas previsões, afeta a composição da BMA da forma apresentada nas Figuras 12, 13 e 14. Elas exibem os boxplots calculados com os pesos atribuídos a cada uma das cadeias chuva-vazão e postos do SIN. A Figura 12 a. apresenta os pesos sem informação temporal de quando foram calculados, ou seja, pesos calculados em tempos distintos foram agrupados por modelo para uma avaliação mais geral dos resultados para postos com SMAP/ONS. Neste caso, observa-se que as cadeias que utilizam o modelo chuva-vazão MGB estão associadas a pesos cujas médias ficam entre 0,03 e 0,08. Além disso, os limites superiores deles também são relativamente baixos, inferiores a 0,35, com ocorrência de alguns *outliers* ultrapassando 0,5. A semelhança entre os pesos aplicados ao GFS-MGB, ETA-MGB, GEFS-MGB, inf(GEFS-MGB), median(GEFS-MGB) e

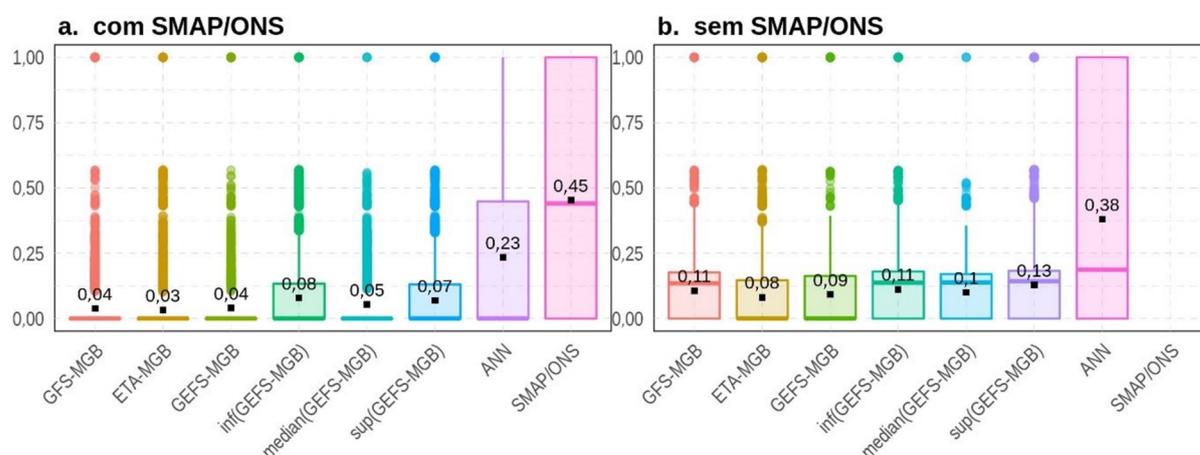


Figura 12 - Boxplot dos pesos calculados para os reservatórios e hidrelétricas do SIN por cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um marcador negro junto ao seu valor numérico.

sup(GEFS-MGB) indica que se não considerarmos a questão temporal, as cadeias chuva-vazão baseadas no MGB tendem a ser ponderadas com pesos de intensidade semelhante. Em contrapartida, quando se observa os boxplots associados à ANN e ao SMAP/ONS, observa-se que a participação dessas cadeias chuva-vazão é mais intensa na composição da BMA. A ANN apresenta uma média de pesos de 0,23, com um limite superior chegando a 1, enquanto o boxplot dos pesos do SMAP/ONS apresenta uma média de 0,45, com um limite superior também igual a 1. Em suma, a Figura 12 a. indica que a BMA sofre grande influência dos modelos SMAP/ONS e ANN, enquanto as outras cadeias apresentam uma participação que é limitada por pesos menores. No caso da Figura 12 b., as cadeias dependentes do MGB apresentam pesos médios maiores do que os verificados na Figura 12 a., com médias variando entre 0,08 e 0,13. Ainda assim, a ANN se destaca por ser o modelo mais importante para a composição da BMA, com média de pesos de 0,38. Dessa forma, pode-se concluir que para o caso dos postos fluviométricos localizados predominantemente no Centro-Oeste, Sudeste e Sul do Brasil, as cadeias SMAP/ONS e ANN são as mais importantes, enquanto no caso dos postos do Norte e Nordeste, a cadeia ANN se destaca dentre as demais.

Quando o tempo é levado em consideração, os pesos aplicados tendem a refletir o comportamento recente das cadeias chuva-vazão. Nas Figuras 13 e 14, são apresentados os boxplots formados pelos pesos computados ao longo do período de *backtest*, considerando um

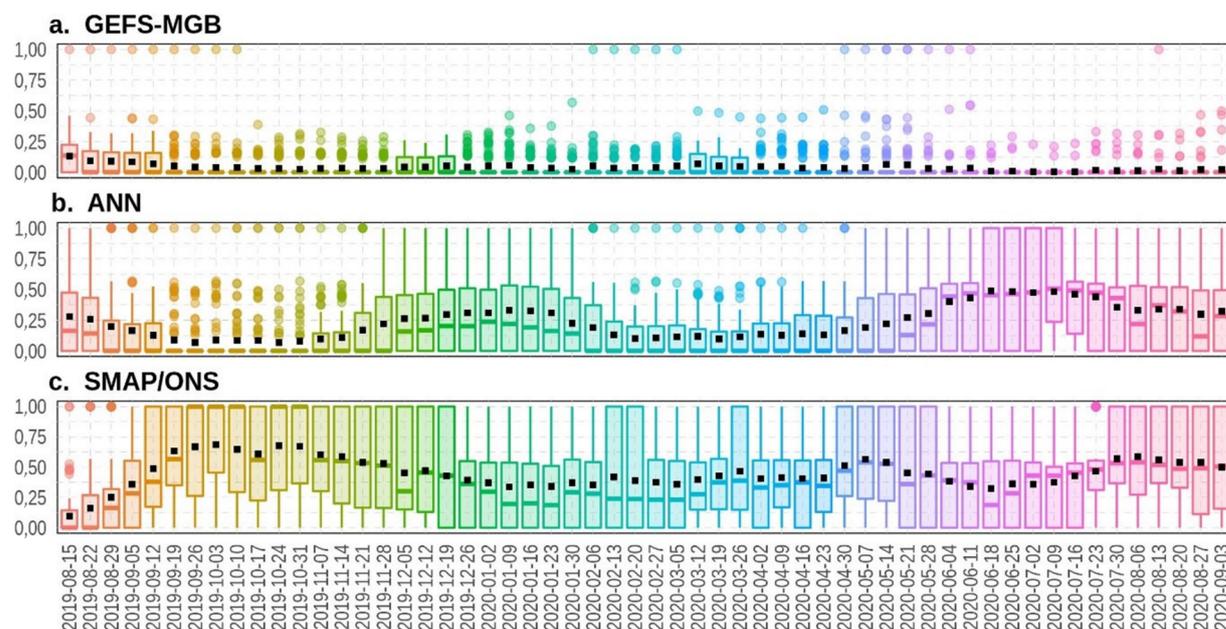


Figura 13 - Boxplots dos pesos calculados para os reservatórios e hidrelétricas do SIN (com vazões simuladas pelo SMAP/ONS) ao longo do tempo. Em cada imagem é apresentada a evolução temporal dos boxplots de pesos computados para todos os postos fluviométricos e cada cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um ponto negro.

intervalo de 7 dias entre boxplots sequenciais. Conforme mostra a Figura 13, associada aos reservatórios e hidrelétricas com vazões afluentes contempladas no SMAP/ONS, cadeias baseadas no modelo MGB sempre apresentam uma média baixa, com valores inferiores a 0,25. A exemplo disso, pode-se observar o caso do GEFS-MGB, cujas médias se aproximam de zero em vários dias. No caso das cadeias ANN e SMAP/ONS, nota-se um padrão diferente daquele observado para as demais cadeias. As médias dos pesos assumem valores mais elevados, próximos de 0,5 para o caso da ANN, com alguns trechos em que há queda para valores torno de 0,25 e 0,00. O SMAP/ONS, por sua vez, destaca-se dentre os demais modelos por apresentar médias que se mantêm próxima a 0,5 na maior parte do tempo, podendo chegar a 0,75 em alguns dias. Além disso, é notável a complementariedade entre os pesos dos modelos ANN e SMAP/ONS. Ao longo do eixo temporal, observa-se que a redução (aumento) dos pesos associados a ANN é simultânea ao aumento (redução) dos pesos aplicados ao SMAP/ONS. No caso dos reservatórios e hidrelétricas cujas vazões afluentes não são contempladas pelo SMAP/ONS, Figura 14, os pesos aplicados às cadeias dependentes do MGB apresentam um padrão similar que pode ser observado para os casos do ETA-MGB e GEFS-MGB. As médias dos pesos são maiores e a frequência que elas vão a zero é reduzida. Enquanto isso, a ANN se destaca por apresentar ao longo de quase todo o eixo temporal pesos elevados e, em alguns casos, próximos de 0,75. Além disso, é interessante salientar que nesse caso não é observada forte complementariedade entre a ANN e um outro modelo específico, como ocorre no caso da Figura 13.

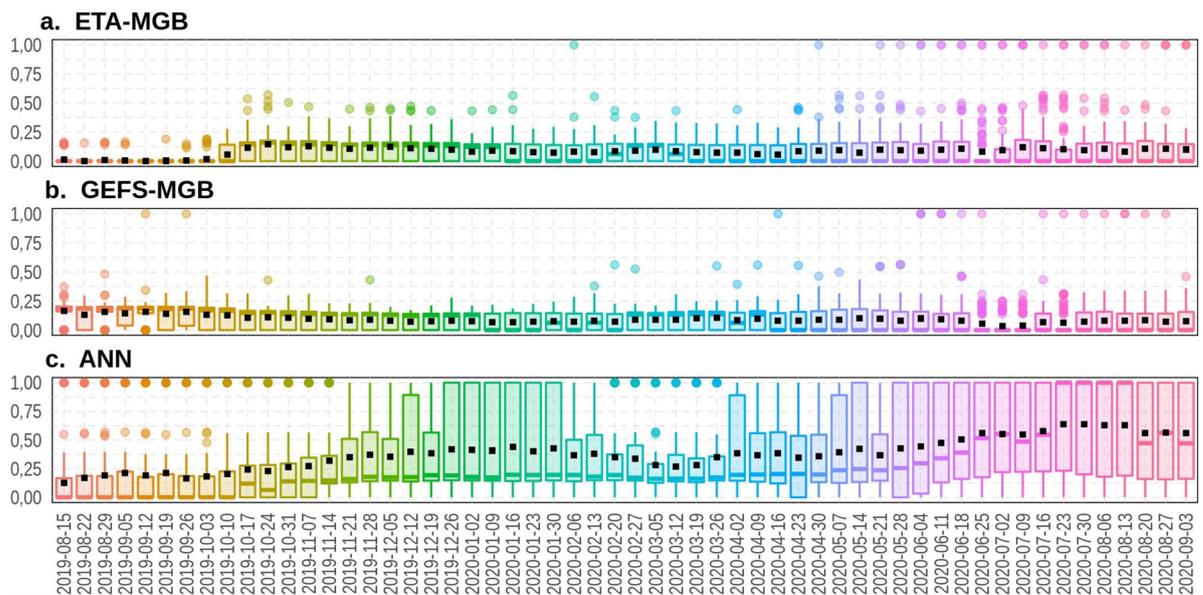


Figura 14 - Boxplots dos pesos calculados para os reservatórios e hidrelétricas do SIN (com vazões não simuladas pelo SMAP/ONS) ao longo do tempo. Em cada imagem é apresentada a evolução temporal dos boxplots de pesos computados para todos os postos fluviométricos e cada cadeia chuva-vazão. A média dos pesos por boxplot é sinalizada por um marcador negro.

---

O *framework* proposto nesse estudo foi desenhado de forma a lidar com a variação comportamental dos modelos. Ao longo do ano, é esperado que o comportamento das cadeias chuva-vazão se altere no período seco, chuvoso e de transição, já que é naturalmente mais difícil realizar previsões de vazão quando o regime de precipitações se torna mais intenso. Essa questão é contornada de forma diferente ao proposto em outros estudos que adotam pesos estáticos para cada período ou trimestre. A abordagem adotada aqui utiliza os dados recentes do histórico de vazões observada e previsões dos membros do *ensemble* para a computação de pesos dinâmicos, que podem ser atualizados até diariamente caso seja necessário. Dessa forma, informações novas dos modelos são incluídas sistematicamente.

## 2.5. CONCLUSÃO

Modelos matemáticos são simplificações de uma realidade que se tenta descrever. “Essencialmente, todos os modelos estão errados, mas alguns são úteis” [96] e facilitam a compreensão, explicação ou previsão de um processo. Inevitavelmente, eles estão sujeitos a incertezas com origens diversas (*i.e.*, *inputs*, condições de inicialização, estrutura e parâmetros) que impactam na qualidade dos resultados. Uma forma de explorar a capacidade preditiva de um conjunto de modelos competidores, é por meio da formação de um MME. Neste capítulo, é abordada a aplicação de inferência bayesiana para a composição de uma previsão de vazão por conjunto, em que as previsões de diversas cadeias chuva-vazão são combinadas utilizando pesos calculados por meio das suas distribuições *a posteriori*. Dessa forma, modelos com performance superior são premiados com pesos elevados, enquanto modelos com performance fraca têm sua participação limitada por ponderadores menores.

A metodologia proposta é voltada para a solução de um problema real, enfrentado diariamente por agentes que atuam no mercado de energia brasileiro e que tomam decisões com base na expectativa de vazões para semana seguinte. Em função de ser uma metodologia focada na aplicação prática, foram levadas em consideração as limitações observadas fora do universo acadêmico, como a) a limitação de dados históricos gerados em tempo real pelas cadeias chuva-vazão e b) a necessidade de utilizar previsões de precipitação como *inputs* (o *framework* foi desenhado para ser uma ferramenta operacional capaz de realizar execuções em tempo real, dessa forma é necessário utilizar previsões de precipitação para o cálculo das vazões futuras via chuva-vazão). No caso de a), essa limitação de dados em conjunto com a necessidade de captar o desempenho recente das cadeias levou à adoção de um esquema dinâmico e semanal (que pode ser

---

convertido para diário, caso seja necessário) de cálculo dos pesos, o que elimina a necessidade de um histórico muito longo de dados para a operacionalização do *framework*. Já no caso de b), é evidente que no momento da execução em tempo real de uma cadeia chuva-vazão os dados de precipitação observada do dia seguinte, ou de N dias à frente, ainda não existem, tornando, portanto, necessária a utilização de dados provenientes de modelos numéricos de previsão de tempo, como o GEFS, GFS, ETA40 e ENS. Ainda com relação a b), é importante ressaltar que a adoção de previsões de precipitação introduz erros que impactam a previsão final de vazão. Contudo, ao incorporar o histórico atualizado de previsões das cadeias chuva-vazão no cálculo dos pesos, essa informação é automaticamente integrada ao processo de combinação dos modelos.

Os resultados da aplicação do *framework* proposto mostram que a performance da BMA, em termos DM, é *em média* superior à performance dos membros do *ensemble* em diversos momentos. Entretanto, quando a antecedência das previsões aumenta, o desempenho do *ensemble* é afetado e a qualidade das previsões diminui. As cadeias chuva-vazão baseadas no modelo MGB geralmente apresentam uma performance inferior àquela observada para as cadeias ANN e SMAP/ONS, independentemente da origem dos dados de previsão de precipitação, com exceção da inf(GEFS-MGB). Dessa forma, os pesos calculados e aplicados as suas previsões indicam que a influência do MGB é bastante limitada na composição da BMA, enquanto os membros ANN e SMAP/ONS são mais valorizados. Apesar dos pesos atribuídos aos membros de menor desempenho serem relativamente pequenos no esquema clássico de aplicação de BMA (diferente do proposto neste estudo), observa-se que quando o número de membros desse tipo cresce, a influência conjunta deles tende a afetar fortemente a previsão por conjunto. No *framework* proposto, optou-se por aplicar o princípio de *Occam's Razor* para a seleção dos membros que efetivamente participam da composição da BMA. Essa estratégia evita que modelos com desempenho significativamente inferior entrem no *ensemble* final, prevenindo a degradação da previsão por conjunto.

Além disso, é importante destacar que a abordagem proposta é mais robusta do que a simples utilização de uma única cadeia chuva-vazão, visto que se leva em consideração a incerteza associada a cada membro do *ensemble* na formação da BMA. Nenhuma das cadeias de entrada apresenta o melhor desempenho para todos os 139 postos fluviométricos considerados. Em geral, uma cadeia com bom desempenho para os postos de uma bacia hidrográfica pode apresentar desempenho médio ou inferior para os postos de outra bacia hidrográfica. Nesta situação, a aplicação do *framework* proposto se mostra relevante por valorizar as previsões das melhores cadeias chuva-vazão em um processo aplicado posto-a-posto.

---

# CAPÍTULO 3

## APLICAÇÃO DE TÉCNICAS DE *MACHINE LEARNING* E ÍNDICES CLIMÁTICOS PARA O APRIMORAMENTO DA PREVISÃO SAZONAL DE PRECIPITAÇÃO NO BRASIL

### 3.1. RESUMO

A previsão climática sazonal de precipitação é essencial para o gerenciamento dos recursos hídricos e para o planejamento das atividades agrícola e de geração de energia hidrelétrica. Esse capítulo propõe o desenvolvimento de modelos híbridos preditivos de precipitação no Brasil utilizando *Multivariable Linear Regression* (MLR) e *Support Vector Machine* (SVM). Para a construção dos modelos, são utilizados como preditores os índices climáticos que descrevem diferentes padrões de teleconexão que afetam a precipitação do Brasil, a *Gauge-Based Analysis of Global Daily Precipitation* do Climate Prediction Center (CPC) e as previsões de precipitação do *Seasonal Forecast System 5* (SEAS5). Os modelos preditivos baseados em MLR e SVM são validados através de simulações feitas para o período que inicia em janeiro de 2017 e termina em dezembro de 2020, utilizando a precipitação registrada pelo CPC como *ground truth*. Os resultados demonstram que em relação ao modelo SEAS5, os modelos MLR e SVM são capazes de aumentar a acurácia e reduzir o viés das previsões de precipitação nas regiões Sudeste, Centro-Oeste e Norte do Brasil no trimestre DJF, enquanto nas regiões Nordeste e Sul possuem performance similar. Ademais, o modelo SVM foi o que apresentou melhor desempenho, demonstrando que as previsões de precipitação no Brasil podem ser aprimoradas.

### 3.2. CONTEXTUALIZAÇÃO

O tempo e o clima são fatores naturais que influenciam diretamente as atividades humanas, tais como agricultura, infraestrutura urbana, transporte fluvial, saúde, energia, entre

---

outros [97], [98], [99], [100], [101]. Especificamente para o caso do Brasil, cuja matriz elétrica é predominantemente hidráulica, a geração de energia elétrica é fortemente dependente das afluições, que são susceptíveis à variabilidade da precipitação [102], [103], [104]. A previsão de precipitação nos diversos horizontes temporais também é relevante para o gerenciamento do uso dos recursos hídricos disponíveis [105], [106], planejamento agrícola [107], [108] e predição de cheias e secas [109]. Enquanto na previsão de tempo o interesse é prever com maior acurácia possível o local de ocorrência e momento de atuação dos sistemas atmosféricos (*e.g.*, a influência de uma frente fria), na previsão climática, o foco é apenas que o sistema seja simulado a fim de contribuir na média das variáveis atmosféricas [110]. Dessa forma, na previsão de clima o interesse é prognosticar se uma dada estação do ano será mais chuvosa ou seca, mais quente ou fria do que o valor médio das variáveis atmosféricas de um determinado local. Esta previsão é de vital importância atualmente visto que os padrões históricos não estão se repetindo em função do aquecimento global [111].

Os desvios em relação ao padrão médio sazonal, que define o clima de uma região, é consequência de alterações no estado básico da atmosférica que afetam a intensidade e/ou frequência de sistemas atmosféricos. Para compreensão dessas alterações, imagine as anomalias na temperatura da superfície do mar (TSM) causando perturbações na atmosfera. O escoamento básico ao ser perturbado, para voltar ao estado original, dispersa ondas que se propagam e afetam a localização, intensidade e/ou frequência dos sistemas atmosféricos atuantes numa dada região que, por consequência, levam a alterações nos valores médios esperados de variáveis como precipitação e temperatura. O link existente entre eventos que ocorrem num dado local do globo e que afetam o clima de regiões remotas é denominado de padrão de teleconexão [112], [113]. Portanto, para a previsão climática, o monitoramento das anomalias de TSM é essencial, pois elas dirigem a variabilidade climática na escala sazonal [114]. No caso do Brasil, vários estudos [115] como, recentemente, em Reboita *et al.* [113] mostram que a TSM exerce um bom controle climático na região Norte, litoral norte do Nordeste e região Sul do país, enquanto as outras áreas apresentam uma resposta mais fraca a essa forçante.

As previsões climáticas sazonais podem ser obtidas, em geral, por três maneiras [115]: (a) o meteorologista analisa as condições oceânicas e de superfície registradas no mês corrente e, em função da lenta variabilidade dessas forçantes, extrapola a informação para o futuro tendo em vista o que os padrões observados podem causar na atmosfera bem como no clima; (b) através de modelos numéricos dinâmicos, que são compostos por equações que descrevem os processos físicos da natureza, sendo amplamente utilizados para a previsão da evolução de sistemas

dinâmicos complexos ao longo do tempo; e (c) através de modelos baseados em dados, que são projetados utilizando variáveis explicativas e algoritmos de aprendizado de máquina para prever, por exemplo, precipitação ou temperatura do ar na superfície (nesses modelos, em geral, é utilizada a TSM como preditor) [116], [117], [118], [119], [120], [121]. As vantagens dos modelos numéricos em relação aos estatísticos é que eles não necessitam de uma extensa base de dados observados para gerar a previsão, produzem uma representação realista dos processos físicos da natureza e não possuem característica estacionária. Por outro lado, os modelos numéricos são muito complexos, caros computacionalmente e necessitam de dados observados precisos para inicialização da previsão [115].

### 3.2.1. ESTUDOS RELACIONADOS

O advento das técnicas de *Machine Learning* desempenhou um papel substancial na evolução da previsão climática ao longo dos últimos anos. Tais algoritmos são capazes de manipular grandes quantidades de dados e reconhecer padrões complexos e não lineares que vão além da compreensão humana. Eles têm a capacidade de aprender com os dados e melhorar suas previsões ao longo do tempo sem o uso de programação explícita. Na literatura especializada sobre modelos baseados em dados, muitos estudos exploraram a aplicação de técnicas de *Machine Learning* na previsão de precipitação para meses à frente. Por exemplo, Quan *et al.* (2006) [122] analisaram o desempenho preditivo e identificaram as fontes da habilidade de previsão de quatro *Atmospheric General Circulation Models* (AGCMs) juntamente com uma coleção de regressões lineares (que usam dados de TSM de 1950 a 1999). Os resultados indicam que a capacidade dos AGCMs de prever a precipitação nos EUA e a temperatura do ar na superfície depende largamente do sinal atmosférico linear do El Niño-Southern Oscillation (ENSO), um desempenho que é comparável ao dos modelos regressivos. Apesar deste resultado, os autores acreditam que ainda precisamos de modelos dinâmicos para realizar previsões sazonais aprimoradas, dado que os métodos estatísticos, mesmo aqueles treinados com 50 anos de dados, podem experimentar flutuações notáveis de desempenho ao longo das décadas. Posteriormente, seguindo uma linha de pesquisa semelhante, Diro *et al.* (2008) [118] projetaram modelos estatísticos para a previsão da precipitação sazonal em oito zonas da Etiópia. Os autores utilizaram dados tropicais e extratropicais de TSM ao redor do mundo como preditores e implementaram técnicas como *Multiple Linear Regression* e *Linear Discriminant Analysis*. Os modelos estatísticos exibiram

---

maior precisão durante anos de precipitação extrema, ilustrando sua eficácia na previsão de níveis de chuva anormalmente altos e baixos.

Ainda em 2006, Coelho *et al.* [123] introduziram uma abordagem nova para o aprimoramento das previsões sazonais de chuva na América do Sul por meio de um sistema integrado de previsão. Esse sistema combina duas estratégias distintas de previsão: um modelo empírico (*Multiple Linear Regression*) que usa anomalias de temperatura da superfície do mar dos oceanos Pacífico e Atlântico, e um *Multi-Model Ensemble* que incorpora modelos de 3 centros climáticos europeus (*Centre National de Recherches Météorologiques - CNRM*, *European Centre for Medium-Range Weather Forecasts – ECMWF* e o *United Kingdom Met Office - UKMO*) que simulam as condições oceânicas e atmosféricas. Ao aplicar técnicas de estatística Bayesiana, as previsões foram aprimoradas, especialmente para o período do verão austral, resultando em estimativas mais confiáveis de chuva. Os resultados indicam que essa abordagem integrada melhora significativamente a precisão das previsões de chuva nos trópicos e em regiões específicas do sul do Brasil, Uruguai, Paraguai e norte da Argentina, especialmente durante eventos de El Niño ou La Niña, embora sua precisão diminua na ausência desses eventos.

Em 2014, Badr *et al.* [124] exploraram o uso de *Artificial Neural Networks* para a previsão de anomalias de precipitação na região do Sahel, na África, usando anomalias de temperatura da superfície do mar e temperatura do ar na superfície como preditores. O estudo enfatiza a performance preditiva superior das redes neurais em comparação a outros modelos estatísticos, atribuindo sua eficácia à capacidade de encapsular as influências não lineares que as forças climáticas de larga escala exercem sobre a precipitação. Posteriormente, em 2016, Gerlitz *et al.* [125] propuseram um modelo baseado em dados usando o algoritmo *Random Forest* para a previsão de anomalias de precipitação na Ásia Central e no sul da Ásia. Um estudo de análise de correlação realizado para a seleção dos preditores revelou uma forte influência do ENSO na precipitação de ambas as regiões, sendo a região central também significativamente impactada pela Oscilação do Atlântico Norte e pelo padrão do Atlântico Leste. Nos testes, o modelo *Random Forest* previu de forma satisfatórias condições úmidas e secas moderadas na Ásia Central; no entanto, a previsão de períodos de seca severa provou ser um desafio ainda a ser superado.

Xu *et al.* (2020) [126] compararam o desempenho de vários modelos dinâmicos e estatísticos na previsão de precipitação na China (incluindo *Linear Regression*, *Long Short-Term Memory - LSTM Neural Network*, *SVM*, e *Random Forest*, bem como os modelos climáticos que compõem o *North American Multi-Model Ensemble - NMME*). Os preditores considerados no processo de modelagem baseada em dados incluíam índices climáticos e dados de precipitação

---

---

histórica decompostos e não decompostos via *Wavelets*, junto com temperaturas médias, mínimas e máximas do ar na superfície. Os modelos com dados de entrada decompostos via *Wavelets* apresentaram desempenho superior aos demais modelos baseados em dados e ao NMME. Esse resultado sugere a presença de efeitos não lineares na precipitação que são revelados através da decomposição via *Wavelets*, o que, por sua vez, permite que os modelos baseados em dados tenham desempenho superior. Posteriormente, seguindo uma linha de pesquisa similar, Anochi, Almeida e Velho (2021) [127] criaram e avaliaram uma *Self-Organized Multilayer Perceptron Neural Network* para a previsão de precipitação na América do Sul, comparando seu desempenho com o *Brazilian Global Atmospheric Model* (BAM). A rede neural demonstrou desempenho superior ao BAM na maioria das regiões, reduzindo particularmente o erro de previsão de 8 mm para 2 mm na região central durante o inverno. No entanto, erros maiores foram observados durante o verão austral (estação chuvosa). Isso foi atribuído aos processos locais e à abundante energia dessa estação, que representam um desafio para as redes neurais devido à limitação de resolução espaço-temporal dos dados usados no processo de treinamento.

Gibson *et al.* (2021) [128] desenvolveram um estudo que aborda o aprimoramento das previsões sazonais de precipitação por meio de modelos baseados em *Machine Learning* treinados com as saídas de modelos climáticos. Focado no oeste dos Estados Unidos, uma região caracterizada por suas condições desafiadoras devido a baixos totais de precipitação e alta variabilidade, o estudo explora o potencial dos modelos baseados em dados para a interpretação das interações complexas entre várias fontes de previsibilidade sazonal, como o ENSO, as anomalias de aquecimento diabático tropical e a variabilidade de correntes de jato. Os resultados do estudo demonstram a habilidade de modelos baseados em *Machine Learning*, como *Random Forest* e *Artificial Neural Networks*, na realização de previsões de precipitação com precisão superior à dos métodos tradicionais. Além disso, o estudo revela preditores-chave e oferece *insights* sobre os processos físicos que impulsionam a precipitação sazonal. A pesquisa também enfatiza que modelos baseados em *Machine Learning*, especialmente quando acoplados a grandes *ensembles* de modelos climáticos, podem fornecer previsões mais precisas e interpretáveis, oferecendo ferramentas valiosas para o gerenciamento de riscos climáticos e meteorológicos.

Em 2021, Wu *et al.* [129] apresentaram um novo modelo híbrido para a previsão de precipitação mensal no nordeste da China. Os autores enfatizaram que, devido à natureza não linear, estocástica e altamente complexa da precipitação, esse tipo de previsão continua sendo um grande desafio. Modelos baseados em *Autoregressive Integrated Moving Average* (ARIMA) e *Artificial Neural Networks*, comumente utilizados na previsão de precipitação, apresentam

---

limitações específicas. O modelo ARIMA é incapaz de emular a estrutura não linear da precipitação, enquanto as redes neurais operam sob a suposição de independência entre as variáveis de entrada e saída. Como solução, o autor propôs a combinação dos modelos mencionados empregando análise multirresolução baseada em *Wavelets* para a formação de um modelo híbrido mais robusto. Os resultados demonstraram que o modelo híbrido proposto superou os modelos originais na previsão de precipitação mensal, desempenho que pode ser atribuído à integração das virtudes de cada modelo, resultando em previsões mais robustas.

Recentemente, em 2023, Pinheiro *et al.* [130] realizaram um estudo sobre a aplicação de um *Ensemble of Artificial Neural Networks* (EANN) para a previsão sazonal de precipitação no Ceará nos meses de fevereiro, março e abril. A pesquisa tinha como objetivo avaliar a habilidade preditiva do EANN e explorar a integração do EANN com modelos dinâmicos, formando a partir daí um *Multi-Model Ensemble* (MME) híbrido. Ao longo de quatro décadas de dados, o estudo comparou o desempenho do EANN com o de modelos estatísticos tradicionais e modelos dinâmicos que compõem o sistema de previsão sazonal do Ceará. Os resultados revelaram que o EANN superou os modelos concorrentes em termos de previsão determinística e probabilística de precipitação, exibindo menor erro quadrático médio e melhor *Ranked Probability Score* na maioria dos setores do Ceará. Além disso, o EANN demonstrou melhor performance na previsão de chuva nas categorias acima e abaixo do normal em comparação aos seus concorrentes. A integração do EANN com modelos dinâmicos, formando um MME híbrido, resultou em um aprimoramento no sentido de reduzir a confiança excessiva em previsões extremas. Além disso, o estudo destaca o potencial do EANN em aprimorar as previsões sazonais de chuva no Ceará e ressalta as vantagens da adoção de abordagens de modelagem híbrida para o refinamento da previsão de precipitação, especialmente diante dos desafios impostos pela variabilidade climática e pela complexidade do regime de precipitação da região.

### 3.2.2. PROPÓSITO DA PESQUISA

Especialmente para o Brasil, o aprimoramento das previsões sazonais de precipitação utilizando modelos baseados em dados é um tema de pesquisa importante que possui relevância nacional, dado o papel crítico dos recursos hídricos na geração de energia elétrica e nas atividades agrícolas. A maior parte da literatura é limitada a setores específicos ou não detalha as regiões geográficas brasileiras [131], [132], [133], [134], [135], apenas alguns estudos recentes consideraram o país como um todo [127], [136]. O estudo proposto aqui se encaixa precisamente

---

nessa linha de pesquisa. Ele tem como objetivo principal contribuir para o desenvolvimento de modelos preditivos capazes de melhorar a acurácia das previsões de até 7 meses à frente para todo o Brasil. Para isso, é proposto um novo *framework* baseado em *Multivariable Linear Regression* (MLR) e *Support Vector Machine* (SVM) que utiliza como preditores os índices climáticos relacionados a padrões de teleconexão climática, as anomalias mensais de precipitação do SEAS5 e as anomalias de precipitação observada do Climate Prediction Center (CPC).

Os métodos MLR e SVM foram inicialmente escolhidos para este estudo pela simplicidade de implementação, por não necessitarem de grandes conjuntos de dados (em comparação às redes neurais) e por apresentarem resultados tão bons, e até equivalentes em alguns casos, aos obtidos com técnicas avançadas na China [126]; o que não exclui a possibilidade de que outras técnicas, além das aplicadas aqui, sejam implementadas no futuro. Além disso, os modelos propostos nesse capítulo inovam ao explorar conjuntamente a capacidade preditiva do modelo dinâmico SEAS5 e os padrões de teleconexão através do uso de *Machine Learning* para a formação de um modelo híbrido específico para cada célula de uma grade sobre o Brasil, trimestre do ano (DJF, MAM, JJA e SON) e mês do horizonte temporal de previsão. Conseqüentemente, índices climáticos relacionados a padrões de teleconexão que afetam apenas setores específicos do país foram empregados nos modelos correspondentes a essas células de grade, o que implica em uma variação espacial do conjunto de preditores efetivamente utilizado pelos modelos.

### 3.2.3. ESTRUTURA DO CAPÍTULO

Esse estudo está organizado da seguinte forma: a Seção 3.2 discorre sobre a complexibilidade das previsões climáticas e os tipos de modelos utilizados; a Seção 3.3 descreve a área de estudo, os dados utilizados, os modelos testados e a forma como eles foram implementados; a Seção 3.4 apresenta, por região do Brasil, os resultados da avaliação do SEAS5 e uma comparação entre sua performance com relação a dos modelos MLR e SVM; e, por fim, a Seção 3.5 expõe as conclusões obtidas e aponta direções para trabalhos futuros.

---

### 3.3. METODOLOGIA

#### 3.3.1. ÁREA DE ESTUDO

A área de estudo compreende o Brasil, país localizado na América do Sul entre as latitudes 34°S-6°N e longitudes 35°W-74°W e limitado pelo polígono com borda mais espessa na Figura 15. Devido a sua grande extensão latitudinal, o Brasil apresenta diversos regimes de precipitação ao longo de seu território [137]. Segundo Quadro *et al.* [138], a Região Norte (N) é caracterizada por um clima equatorial com elevados níveis de precipitação e um curto período seco, com total pluviométrico anual entre 1500 e 2500 mm na maior parte da região e valores superiores a 2500 mm no seu noroeste; o Nordeste (NE), por sua vez, contrasta com o Norte ao apresentar um clima semiárido no seu interior, em que a estação chuvosa é de curta duração com baixos níveis pluviométricos, entre 200 e 800 mm, enquanto um clima mais chuvoso é verificado ao noroeste e ao longo da costa leste; as Regiões Centro-Oeste (CO) e Sudeste (SE) apresentam as estações seca

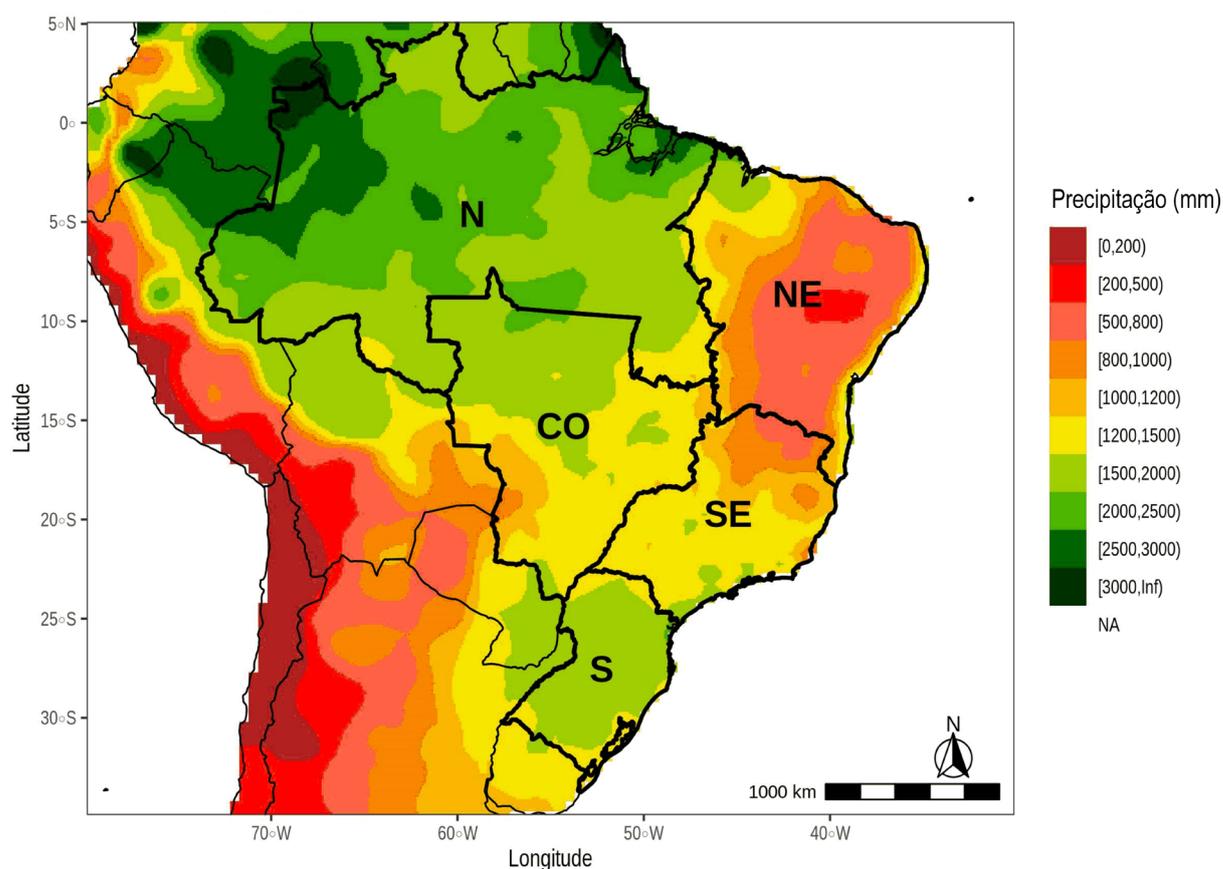


Figura 15 - Precipitação média anual nas regiões do Brasil obtida a partir dos dados do *Gauge-Based Analysis of Global Daily Precipitation* [139] no período de jan-1993 a dez-2016. O Brasil está limitado por um polígono com borda mais espessa na cor preta e os acrônimos N, CO, NE, SE e S indicam, respectivamente, região Norte, Centro-Oeste, Nordeste, Sudeste e Sul.

e chuvosa bem definidas ao longo do inverno e verão austral, sofrendo influência de sistemas atmosféricos tropicais e de latitude média que resultam em médias anuais de precipitação entre 1200 e 1500 mm, com uma redução desse intervalo ao norte do SE (500 a 1200 mm) e aumento no norte do CO (1500 a 2000 mm); enquanto a região Sul (S) sofre influência de sistemas frontais ao longo do ano, sendo esses os principais causadores de chuva nessa região de latitudes mais altas, que possui uma média anual de precipitação entre 1500 e 2000 mm.

### 3.3.2. DADOS

#### 3.3.2.1. Análise de Precipitação do CPC

O *Gauge-Based Analysis of Global Daily Precipitation* [139] é um produto do CPC gerado pela combinação de dados diários, acumulados entre 12:00 e 12:00 UTC do dia seguinte, de cerca de 30.000 estações meteorológicas utilizando técnicas de interpolação [139], [140]. A análise de precipitação é construída considerando uma resolução horizontal de  $0,125^\circ$  para toda a área continental global, mas disponibilizada publicamente em uma resolução espacial horizontal de  $0,5^\circ$  em [141]. De acordo com os estudos de Silva *et al.* [142], Carvalho *et al.* [143], Almeida *et al.* [144] e Torres *et al.* [64], o CPC tem apresentado resultados consistentes e satisfatórios na representação espacial da precipitação histórica medida *in situ*, podendo ser utilizado no monitoramento e avaliação de sistemas sinóticos ou características climáticas em diferentes escalas temporais como, por exemplo, o sistema de monções, bem como na validação de previsões. Neste estudo, os dados de precipitação do CPC de jan-1992 a dez-2020 foram utilizados para o cálculo das séries temporais de precipitação acumulada mensal para todo o Brasil.

#### 3.3.2.2. Precipitação do SEAS5

O SEAS5 [145], [146] é um sistema de modelagem global acoplado que prognostica a evolução do oceano e atmosfera em escala sazonal. Ele foi desenvolvido pelo ECMWF e substituiu o modelo climático System 4 (S4) em 5 de novembro de 2017 [147]. A cada execução do SEAS5, que ocorre no primeiro dia de cada mês, são geradas previsões sazonais de precipitação com resolução espacial horizontal de 37 km. Esses dados são disponibilizados gratuitamente com  $1^\circ$  de resolução espacial horizontal e horizonte temporal de 215 dias, o equivale a cerca de 7 meses. Desde sua operacionalização, o SEAS5 gera mensalmente um *ensemble* com um total de 51 membros (*i.e.*, resultados das simulações de *forecast*), dos quais um deles é o membro de controle

enquanto os demais são gerados considerando uma combinação de perturbações nas condições iniciais da atmosfera e da temperatura da superfície do mar no modelo numérico. Além disso, o SEAS5 dispõe de um *ensemble* de 25 membros para calibração que foi gerado via *reforecast* (*hindcast*) para o período de jan-1993 a dez-2016. Com o intuito de reduzir o volume de dados a serem processados, optou-se por trabalhar com a média simples das previsões feitas pelos membros do modelo. Ademais, os dados do período de *hindcast* (jan-1993 a dez-2016) e *forecast* (jan-2017 a dez-2020), disponíveis no sítio eletrônico [148], foram utilizados no cálculo das previsões de precipitação mensal acumulada do SEAS5.

### 3.3.2.3. Índices Climáticos

Sabendo-se que a variabilidade do clima é decorrente, em sua maior parte, da influência das anomalias de TSM, tem-se a necessidade de se estudar os padrões de interação oceano-atmosfera que ocorrem num dado local e afetam o clima de regiões remotas [112], [113], [149]. Dentre os padrões de teleconexão existentes, alguns dos quais exercem impacto no Brasil são: El Niño-Oscilação Sul, Dipolo do Atlântico Tropical, Dipolo do Oceano Índico, Dipolo do Atlântico Subtropical, Padrão Pacífico-América do Sul, Anomalias de TSM na costa sul do Brasil e Uruguai e Variabilidade do Anticiclone do Atlântico Sul [113], [150]. Esses padrões são monitorados através de índices que são disponibilizados periodicamente por centros meteorológicos via internet. Esses centros também fornecem explicações detalhadas sobre como os índices são calculados. Na Tabela 3, são apresentados os índices utilizados no presente estudo e as suas fontes. Em todos os casos, foram obtidos dados relativos ao período que vai de jun-1992 a dez-2020, conforme será relatado na seção que trata dos modelos estatísticos.

Tabela 3 - Índices climáticos de teleconexão e suas fontes de dados.

Índices	Detalhes	Link
Niño 1+2, 3, 3.4 e 4	Cada índice é definido como a anomalia da TSM média [151], [152] em regiões específicas do Oceano Pacífico Tropical, baseadas no produto ERSST v5 [153]. Niño 1+2: região (0°-10°S, 90°W-80°W), Niño 3: região (5°N-5°S, 150°W-90°W), Niño 3.4: região (5°N-5°S, 170°W-120°W) e Niño 4: região (5°N-5°S, 160°E-150°W).	<a href="https://psl.noaa.gov/data/correlation/nina1.anom.data">https://psl.noaa.gov/data/correlation/nina1.anom.data</a> <a href="https://psl.noaa.gov/data/correlation/nina3.anom.data">https://psl.noaa.gov/data/correlation/nina3.anom.data</a> <a href="https://psl.noaa.gov/data/correlation/nina34.anom.data">https://psl.noaa.gov/data/correlation/nina34.anom.data</a> <a href="https://psl.noaa.gov/data/correlation/nina4.anom.data">https://psl.noaa.gov/data/correlation/nina4.anom.data</a>
Oceanic Niño Index (ONI)	O ONI [154] é baseado na média móvel de três meses consecutivos da anomalia de TSM média na região do Niño 3.4 calculada com dados do ERSST v5 [153].	<a href="https://psl.noaa.gov/data/correlation/oni.data">https://psl.noaa.gov/data/correlation/oni.data</a>

Southern Oscillation Index (SOI)	O SOI [155] é um índice mensal definido como a diferença entre as anomalias padronizadas de pressão ao nível do mar no Tahiti e Darwin. Mais informações sobre o equacionamento podem ser obtidas em [156].	<a href="https://psl.noaa.gov/data/correlation/soi.data">https://psl.noaa.gov/data/correlation/soi.data</a>
Multivariate ENSO Index (MEI)	O MEI [157], [158] é a primeira componente calculada através da técnica de análise de componentes principais aplicada às anomalias de pressão ao nível do mar, TSM, ventos zonais superficiais, ventos meridionais superficiais e radiação de onda longa na região (30°S-30°N, 100°E-70°W) do Oceano Pacífico [159].	<a href="https://psl.noaa.gov/enso/mei/data/meiv2.data">https://psl.noaa.gov/enso/mei/data/meiv2.data</a>
Bivariate ENSO Time Series (BEST)	O índice BEST [160] é calculado pela combinação das séries temporais padronizadas de anomalias de TSM ocorridas na região Niño 3.4 com o SOI.	<a href="https://psl.noaa.gov/data/correlation/censo.data">https://psl.noaa.gov/data/correlation/censo.data</a>
Trans-Niño Index (TNI)	O TNI [152] é calculado pela diferença entre as anomalias normalizadas da TSM média nas regiões do Niño 1+2 e Niño 4.	<a href="https://psl.noaa.gov/data/correlation/tni.data">https://psl.noaa.gov/data/correlation/tni.data</a>
Tropical Northern Atlantic (TNA)	O índice TNA [161] é definido como a anomalia da TSM média na região (5,5°N-23,5°N, 15°W-57,5°W), sendo baseado nos dados do produto HadISST e NOAA OI 1x1.	<a href="https://psl.noaa.gov/data/correlation/tna.data">https://psl.noaa.gov/data/correlation/tna.data</a>
Tropical Southern Atlantic (TSA)	O índice TSA [161] é definido como a anomalia da TSM média na região (0°-20°S, 10°E-30°W), sendo baseado nos dados do produto HadISST e NOAA OI 1x1.	<a href="https://psl.noaa.gov/data/correlation/tsa.data">https://psl.noaa.gov/data/correlation/tsa.data</a>
Dipole Mode Index (DMI)	O DMI [162], [163] é calculado pela diferença entre as anomalias de TSM média nas regiões oeste (50°E-70°E, 10°S-10°N) e sudeste (90°E-110°E, 10°S-0°) do Oceano Índico Equatorial com os dados do produto HadISST.	<a href="https://psl.noaa.gov/gcos_wgsp/TimeSeries/Data/dmi.had.long.data">https://psl.noaa.gov/gcos_wgsp/TimeSeries/Data/dmi.had.long.data</a>
South Atlantic Ocean Dipole Index (SAODI)	O SAODI [164] é definido como a diferença normalizada entre as anomalias de TSM média nos setores nordeste (15°S-0°, 10°E-20°W) e sudoeste (25°S-40°S, 10°W-40°W) do Oceano Atlântico Sul calculada com os dados do produto ERSST v5 [153].	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=saodi">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=saodi</a>
South Atlantic Subtropical Dipole Index (SASDI)	O SASDI [165] é definido como a diferença normalizada entre as anomalias de TSM média nos setores nordeste (15°S-25°S, 0°-20°W) e sudoeste (30°S-40°S, 10°W-30°W) do Oceano Atlântico Sul calculado com os dados do produto ERSST v5 [153].	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=sasdi">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=sasdi</a>
Pacific South American 1 (PSA1)	O índice PSA 1 [166], [167], [168] é a segunda componente calculada através da aplicação da técnica de análise de componentes principais às anomalias sazonais de altura geopotencial em 700 hPa.	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=psa1">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=psa1</a>
Pacific South American 2 (PSA2)	O índice PSA 2 [166], [167], [168] é a terceira componente calculada através da aplicação da técnica de análise de componentes principais às anomalias sazonais de altura geopotencial em 700 hPa.	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=psa2">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=psa2</a>
Índice de TSM na RG2 (ITSRMG2)	O ITSRMG2 [113], [169], [170] é definido como a anomalia da TSM média na região (40°S-30°S e 57°-47°W) entre o sul do Brasil e o Uruguai com os dados do produto ERSST v5 [153].	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=itsmrg2">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=itsmrg2</a>
Índice do Anticiclone Subtropical do Atlântico Sul (IASAS)	O IASAS [171] é obtido calculando-se a diferença entre as anomalias mensais de pressão atmosférica ao nível médio do mar entre as regiões Sudeste (25°S-15°S, 50°W-40°W) e Sul (37.5°S-27.5°S, 60°W-50°W) do Brasil com os dados do produto ERA 5 reanalysis.	<a href="https://meteorologia.unifei.edu.br/teleconexoes/indice?id=iasas">https://meteorologia.unifei.edu.br/teleconexoes/indice?id=iasas</a>

---

### 3.3.3. MODELOS ESTATÍSTICOS

#### 3.3.3.1. Formatação dos *Inputs*

Os modelos implementados nesse estudo utilizam como *inputs* as séries temporais das três bases de dados descritas na Seção 3.3.2. A forma como os dados são utilizados para alimentação dos modelos varia de acordo com o tipo de dado utilizado, conforme descrito a seguir.

O primeiro conjunto de dados de entrada dos modelos MLR e SVM é constituído pelos índices associados aos padrões de teleconexão. No momento da previsão, as informações associadas aos meses que estão sendo previstos não estão disponíveis, logo é necessário utilizar dados do passado. Para isso, os índices calculados para meses anteriores, que já fazem parte da série histórica de dados, são utilizados como *inputs*. Neste estudo, foram considerados os valores dos últimos 7 meses da série temporal de cada índice, conforme mostra a Figura 16 a., onde as previsões feitas em jan-2016 para os meses de jan-2016 a jul-2016 utilizam dados dos 7 meses passados, isto é, meses de jun-2015 a dez-2015.

Quanto ao segundo conjunto de dados de preditores, a Figura 16 b. ilustra a aplicação dos resultados das execuções do sistema dinâmico do ECMWF. A série temporal das diferenças entre as previsões do SEAS5 e a normal climatológica de precipitação fornece informações sobre a quantidade de chuva — seja um aumento ou uma diminuição — que o modelo climático prevê para os próximos sete meses, usando como referência a média de precipitação dos últimos anos. No exemplo da Figura 16 b., as previsões feitas em jan-2016 para os meses de jan-2016 a jul-2016 utilizam os resultados das execuções do SEAS5 também inicializadas em jan-2016 como *inputs*.

As séries históricas de anomalia de precipitação do CPC formam o terceiro e último conjunto de dados de entrada dos modelos estatísticos. Assim como ocorre para o caso dos índices de teleconexão, os dados de precipitação para o mês que está sendo previsto não estão disponíveis quando é feita a previsão. Dessa forma, é necessário utilizar dados associados a meses passados que estejam presentes na série temporal do CPC. Portanto, são considerados como *inputs* os valores dos últimos 12 meses, conforme mostra o exemplo da Figura 16 c., onde as previsões feitas para os próximos sete meses, jan-2016 a jul-2016, utilizam dados dos meses de jan-2015 a dez-2015. Observe que, à medida que o mês do horizonte de previsão se distancia do momento em que é feita a previsão, menos informações de curto prazo estão disponíveis para alimentar os modelos baseados em dados.

---

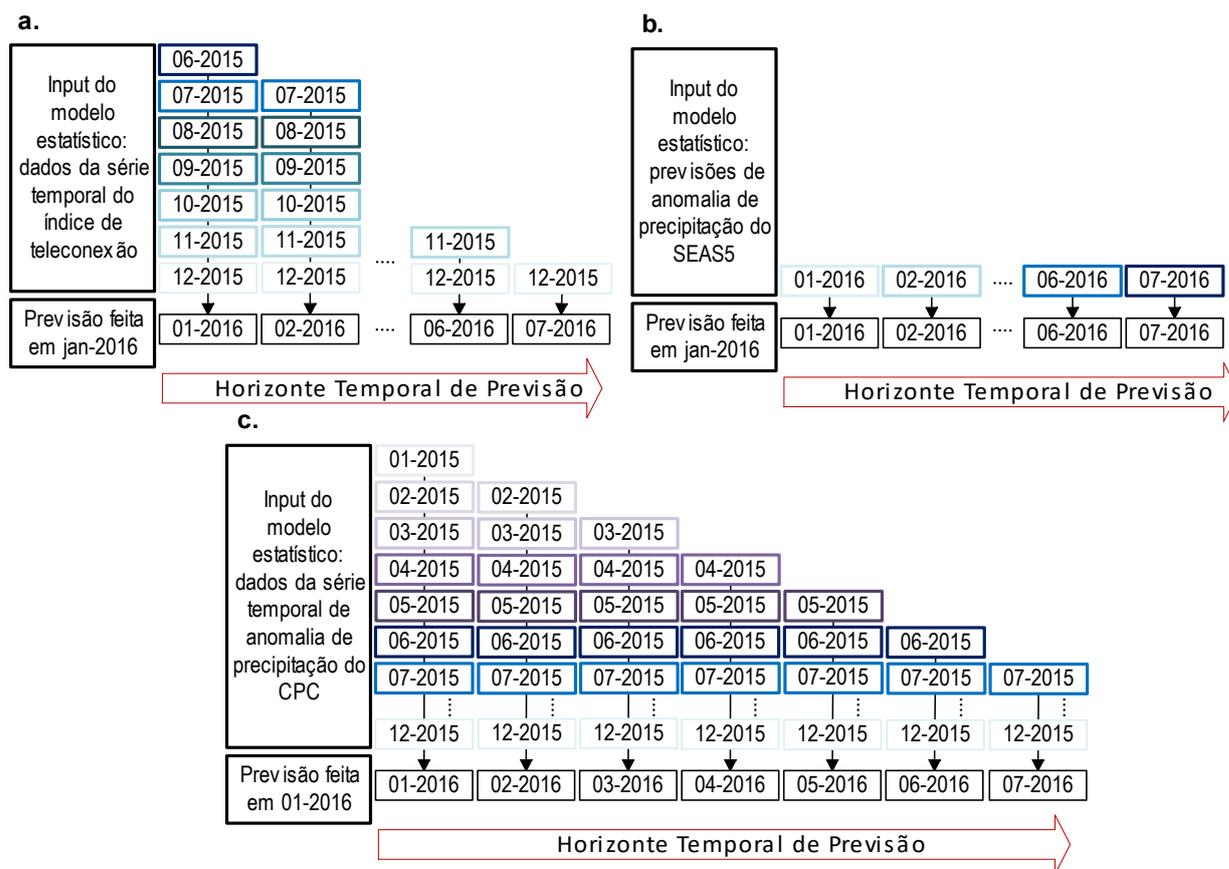


Figura 16 - Inputs dos modelos MLR e SVM. (a.) exemplifica como os dados da série temporal de um índice climático são utilizados para previsão sazonal de anomalia de precipitação (e.g., a previsão realizada em jan-2016 para o período de jan-2016 a jul-2016 utiliza os últimos 7 meses da série temporal do índice). (b.) detalha a aplicação das anomalias de precipitação do SEAS5 (e.g., a previsão realizada em jan-2016 para o período jan-2016 a jul-2016 utiliza os dados das execuções do SEAS5 que foram inicializadas em jan-2016). (c.) indica como as anomalias de precipitação do CPC são empregadas (e.g., a previsão realizada em jan-2016 para o período jan-2016 a jul-2016 usa dados históricos dos últimos 12 meses).

Em suma, os dados são processados da seguinte maneira para a composição dos três conjuntos de preditores:

- **Séries temporais de índices climáticos defasadas de 1 a 7 meses:** 18 índices x 1-7 meses de defasagem = 126 preditores;
- **Anomalias de precipitação do SEAS5 para 1 a 7 meses à frente:** 7 preditores;
- **Anomalias de precipitação CPC defasadas de 1 a 12 meses:** 12 preditores.

### 3.3.3.2. Regressão Linear Multivariada

A Regressão Linear Múltipla [172], ou *Multivariable Linear Regression* (MLR), é um modelo estatístico clássico orientado por dados que descreve uma variável dependente  $y$  em função de um conjunto de variáveis independentes  $x_1, x_2, \dots, x_n$ , também conhecidas como preditores. Na literatura especializada, esse tipo de regressão tem aplicações em problemas de previsão de precipitação sazonal [126], secas hidrológicas [173], vazões em rios [174], [175] e geração de energia eólica [176]. A variável dependente  $y$  se vincula às variáveis independentes  $x_1, x_2, \dots, x_n$  por meio da relação temporal linear representada na Equação (14), onde  $\beta_0$  é o coeficiente linear,  $\beta_1, \beta_2, \dots, \beta_n$  são os coeficientes angulares aplicados aos preditores e  $\varepsilon$  é o resíduo do modelo. Nesse modelo regressivo, os coeficientes angulares ponderam os preditores e influenciam na participação de cada variável independentes na composição de  $y(t)$ . Eles são termos constantes calculados por meio do método dos mínimos quadrados [177] que, basicamente, identifica os coeficientes que minimizam a soma dos quadrados dos resíduos do modelo.

$$y(t) = \beta_0 + \beta_1 x_1(t) + \beta_2 x_2(t) + \dots + \beta_n x_n(t) + \varepsilon(t) \quad (14)$$

#### 3.3.3.2.1. Seleção de Variáveis de Entrada

Para a criação das MLRs previsoras de anomalia de precipitação, a seleção das variáveis preditoras foi otimizada por célula de grade utilizando o método *Stepwise* em que os preditores significativos para o modelo são escolhidos via Teste de Hipótese de Fisher [178] (F-test). Nesse método, as variáveis independentes passam por uma análise rigorosa; elas são adicionadas sequencialmente (em iterações *forward*) ou removidas (em iterações *backward*) com base em sua significância estatística para o modelo regressivo, configurando um processo bidirecional de seleção de entradas. Isso garante que o modelo final abarque apenas aqueles preditores que fornecem contribuições significativas e estatisticamente relevantes. O objetivo é equilibrar a simplicidade do modelo e a performance preditiva, eliminando variáveis supérfluas que não melhorem o desempenho do modelo.

Uma descrição detalhada do algoritmo de regressão *Stepwise* bidirecional é fornecida abaixo:

- **Inicialização:** o processo começa com um modelo “vazio” e a escolha dos níveis de significância para a inserção e remoção de preditores. Estes são tipicamente denotados como *alpha-to-enter* e *alpha-to-remove* (por exemplo,  $\alpha = 0,05$  em ambos os casos);

- **Etapa de seleção *forward*** (adição de preditores): inicialmente, os preditores são classificados e ranqueados de acordo com certo critério, como, por exemplo, a correlação de Pearson entre eles e a variável de previsão. O primeiro preditor do *ranking* é adicionado ao modelo MLR se o *p – value* relacionado for menor que o *alpha-to-enter* (o *p – value* é calculado usando o F-test). Esta etapa é repetida, considerando os preditores restantes do *ranking*, até que nenhuma variável atenda ao critério de entrada;
- **Etapa *backward*** (remoção de preditores): o preditor que apresenta a menor contribuição para o modelo MLR deve ser removido (aquele com o maior *p – value* do grupo) se seu *p – value* for maior que o *alpha-to-remove* (o *p – value* é calculado usando o F-test). Esta etapa é repetida, considerando os preditores restantes, até que nenhuma variável atenda ao critério de saída;
- **Iteração:** alternância entre as etapas *forward* e *backward*. Em cada iteração, o modelo é reavaliado e a significância de cada variável é analisada;
- **Critério de parada:** o processo finaliza quando nenhum preditor fora do modelo tiver um *p – value* menor que o *alpha-to-enter* e nenhum preditor dentro do modelo tiver um *p – value* maior que o *alpha-to-remove*. Nesse ponto, o modelo MLR é considerado otimizado de acordo com os critérios do método *Stepwise*.

### 3.3.3.3. Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte [179], [180], ou *Support Vector Machine* (SVM), é um algoritmo de *Machine Learning* originalmente criado para solução de problemas de classificação de dados, que posteriormente teve sua aplicação estendida para problemas de regressão. O método tem sido amplamente aplicado em problemas de previsão. Exemplos incluem a previsão de precipitação sazonal [126], velocidade do vento no curto prazo e geração de energia [131], [181], [182], vazões em rios [183], [184] e enchentes urbanas repentinas [185]. O conceito básico do modelo consiste em calcular o hiperplano  $y_i = w^t x + b$  (*i.e.*, o modelo regressivo) que maximiza a margem de tolerância a erros  $\varepsilon$  por meio de  $w$ , conforme mostra o problema de programação matemática em (15).

A abordagem SVM visa produzir um modelo de regressão que se ajuste melhor ao conjunto de dados de treinamento e minimize o erro de generalização, usando os pontos mais externos do conjunto de dados como referência. A Equação (15) ilustra o problema de

programação matemática do modelo SVM, onde  $w$  é o vetor perpendicular ao hiperplano ótimo,  $b$  é uma constante e  $y_i$  e  $x_i$  são os dados utilizados no treinamento do modelo, respectivamente. A função objetivo em (15) busca maximizar a margem retratada na Figura 17 (que é proporcional a  $1/\|w\|$ ), com restrições formando os hiperplanos fronteiros, onde os erros permanecem abaixo de  $\varepsilon$ .

$$\min_{w,b} \frac{1}{2} \|w\|^2, \quad s. t. \begin{cases} y_i - w^t x_i - b \leq \varepsilon \\ w^t x_i + b - y_i \leq \varepsilon \end{cases} \quad (15)$$

O termo  $\|w\|^2$  em (15) é conhecido como penalização de Ridge. Ele é frequentemente empregado em modelos estatísticos para fins de regularização. Central para a metodologia SVM, sua essência reside em penalizar a magnitude dos pesos  $w$ , orientando a criação de SVMs mais simples e generalizáveis com pesos minimizados. Esta técnica de regularização também é essencial para moderar o impacto de preditores correlacionados, garantindo que os modelos permaneçam resilientes a pequenas flutuações de dados, além de ajudar a superar os desafios da multicolinearidade.

### 3.3.3.3.1. Tratamento de Não Linearidades Usando *Kernels*

No contexto de modelos regressivos, a SVM se destaca por ser aplicável em problemas não lineares sem necessitar de grandes conjuntos de dados. Para isso, ela usa funções  $\Phi$  que transformam os dados e aumentam a dimensionalidade de modo a simplificar o processo de determinação do hiperplano ótimo, conforme mostra a Figura 17. A nova formulação do problema de programação matemática é expressa pela Equação (16), onde são também consideradas variáveis de folga  $\xi_i$  e  $\xi_i^*$  cuja finalidade é evitar o *overfitting* do modelo.

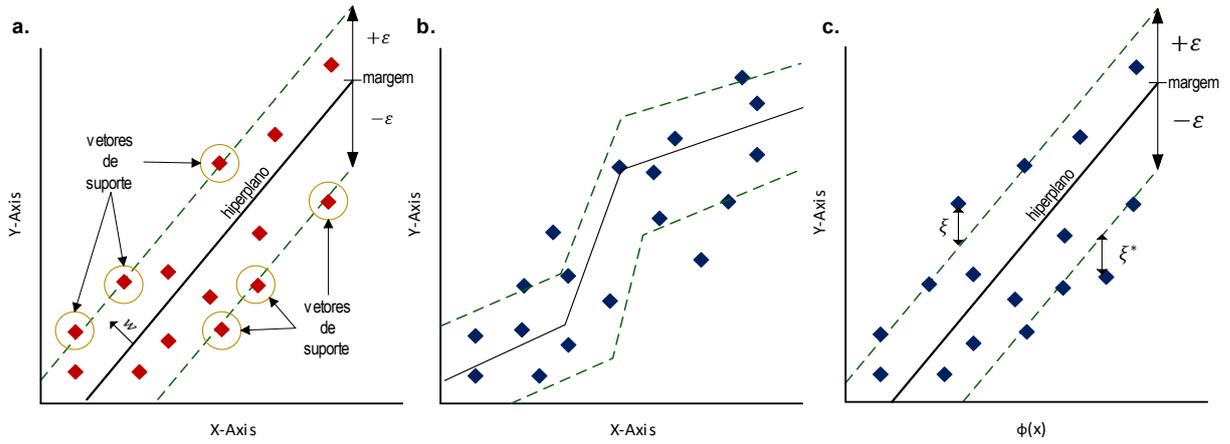


Figura 17 - Diagramas de regressão SVM. Em (a.) ilustra-se os conceitos básicos por trás da metodologia SVM (ou seja, vetores de suporte, hiperplano ótimo e margem de erro). (b.) e (c.) exemplificam o uso de funções de *kernel* para remapear os dados  $x_i$  de um espaço de baixa para um de alta dimensão  $\Phi(x_i)$  onde o processo de regressão pode ser realizado com maior facilidade.

$$\min_{w,b,\xi_i,\xi_i^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*), \quad s. t. \begin{cases} y_i - w^t \Phi(x_i) - b \leq \epsilon + \xi_i \\ w^t \Phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (16)$$

O problema de programação matemática da Equação (16) tem sua solução determinada através de sua versão dual [186], conforme pode ser conferido em detalhes no artigo de Smola *et al.* [187]. A solução final obtida pelos autores, após uma série de simplificações e substituições, é apresentada na Equação (17), em que  $\alpha$  e  $\alpha_i$  são as variáveis duais (*i.e.*, multiplicadores de Lagrange associados às duas primeiras inequações em (16)) e o produto  $\Phi(x_i)^t \Phi(x)$  é denominado função *kernel*  $K(x_i, x)$ , termo responsável pela transformação do conjunto de dados de forma implícita (*i.e.*, sem a necessidade de explicitar a expressão matemática de  $\Phi$ , apenas a expressão resultante de  $\Phi(x_i)^t \Phi(x)$ ).

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (17)$$

No estudo discutido aqui, a função *kernel* sigmoidal  $K(x_i, x) = \tanh(\gamma x_i^t x + c_0)$ , onde  $\gamma$  e  $c_0$  são parâmetros fixos, foi escolhida após a realização de testes com funções *kernels* lineares, polinomiais e de base radial. Os valores ótimos dos parâmetros calibráveis do modelo SVM,  $\gamma$  e  $c_0$ , foram determinados por meio de um processo heurístico usando a função `tune.svm` do pacote `e1071` em linguagem R. A função `tune.svm` utiliza uma estratégia iterativa denominada *5-fold cross-validation* para o ajuste dos parâmetros de SVMs. Nesse processo, os dados de 1993 a 2016

são divididos em 5 subconjuntos distintos que são explorados em série. Em cada uma das iterações, quatro subconjuntos são utilizados para treinamento do modelo, enquanto o quinto subconjunto, diferente a cada rodada, é destinado à validação. Essa abordagem iterativa facilita uma avaliação abrangente da performance do modelo e de sua adaptabilidade a diferentes subconjuntos de dados. Uma vez concluído esse processo, a função fornece o modelo com melhor ajuste, pronto para a realização de previsões.

### 3.3.3.3.2. Seleção de Variáveis de Entrada

A seleção de preditores via análise de correlação é uma abordagem estratégica para a escolha de preditores com base na sua relação com a variável alvo do estudo. Este método revela-se particularmente eficaz na redução do volume de dados de entrada e na otimização do desempenho de modelos fundamentados puramente em dados (*data-driven models*). No problema de previsão de precipitação, o conjunto final de preditores considerados foi otimizado para cada célula da grade, utilizando como critério de seleção a correlação entre as séries temporais de cada preditor e as anomalias de precipitação do CPC. Apenas preditores com correlações acima de 0,2 ou abaixo de -0,2 compõem o conjunto de entrada das SVMs. Esta faixa abrange preditores com diferentes graus de força de correlação, estendendo-se de fraco a extremamente forte, conforme classificado por Evans [188]. A justificativa para a adoção de um limiar relativamente baixo decorre da observação de que as correlações entre anomalias de precipitação e índices climáticos geralmente não alcançam magnitudes substanciais.

À primeira vista, esse valor pode não parecer altamente seletivo. No entanto, ele concede às SVMs maior liberdade para explorar o conjunto de preditores, concentrando-se nos mais promissores, e reduz a dimensão do problema ao descartar aqueles com um valor de correlação absoluta abaixo do limiar. Além disso, é importante lembrar que as SVMs também possuem um termo de regularização na sua função objetivo (penalização de Ridge  $\|w\|^2$ ) que minimiza os pesos atribuídos a qualquer preditor que não se prove relevante para o modelo, evitando também a dependência excessiva em um preditor específico.

### 3.3.3.4. Principais Preditores por Modelo e Região Geográfica

Na Seção 3.3.3.1, foram introduzidos três conjuntos de preditores para a previsão sazonal de precipitação no Brasil: anomalias de precipitação do CPC, índices climáticos e anomalias de precipitação do SEAS5. Contudo, é importante destacar que, conforme detalhado nas Seções

3.3.3.2.1. e 3.3.3.3.2., nem todos os preditores listados na Seção 3.3.3.1 são incorporados aos modelos baseados em dados. A exclusão de preditores candidatos decorre do fato de que nem todos eles são capazes de explicar a variabilidade da precipitação sazonal nas células da grade consideradas neste estudo. Essa limitação torna-se particularmente evidente para o caso dos índices climáticos que monitoram padrões de teleconexão que afetam regiões específicas do Brasil. Em tais casos, nem todas as anomalias de precipitação verificadas nas células de grade estão relacionadas aos índices climáticos considerados neste estudo. Portanto, um processo de pré-seleção é necessário para determinar os preditores mais relevantes para cada célula.

No processo de construção dos modelos baseados em MLR (Regressão Linear Múltipla), o Teste de Hipótese de Fisher é aplicado para refinar o conjunto final de preditores, selecionando aqueles que possuem uma relação estatisticamente significativa com a variável prevista (ou seja, apenas aqueles que melhoram significativamente a qualidade do ajuste do modelo de regressão são mantidos). Por outro lado, para as SVMs, considera-se apenas os preditores que têm uma correlação maior que 0,2 ou menor que  $-0,2$  com as anomalias de precipitação registradas em cada célula da grade. A Tabela 4 ranqueia os preditores detalhados na Seção 3.3.3.1. de acordo com seu nível de participação nos modelos desenvolvidos para a previsão de chuva no trimestre DJF (para o caso dos trimestres MAM, JJA e SON, foram disponibilizadas as Tabelas 7, 8 e 9 no apêndice do presente capítulo). Os percentuais definem o nível de participação de cada preditor no conjunto de modelos desenvolvidos para as regiões SE, CO, S, NE e N, sendo destacados (por questões de concisão) apenas os sete preditores que lideram o ranking. Os resultados revelam que os dados de anomalias de precipitação do CPC e SEAS5 são comumente explorados em todas as

Tabela 4 - *Ranking* dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre DJF).

Modelos	Ranking	SE [320 células]		CO [542 células]		S [207 células]		NE [512 células]		N [1259 células]	
		Variável	%	Variável	%	Variável	%	Variável	%	Variável	%
MLR	1	CPC	54,7	CPC	47,5	CPC	34,2	CPC	29,0	CPC	31,1
MLR	2	SEAS5	12,5	SEAS5	12,4	SEAS5	14,4	PSA1	19,4	RG2SSTI	6,7
MLR	3	RG2SSTI	8,0	RG2SSTI	11,3	Niño 1+2	6,7	SEAS5	13,0	SEAS5	6,4
MLR	4	SAODI	6,1	TNA	5,5	RG2SSTI	5,4	SASDI	5,9	TNA	5,2
MLR	5	PSA1	5,8	PSA1	3,6	PSA2	4,1	RG2SSTI	5,2	ONI	5,0
MLR	6	TNA	3,2	Niño 1+2	2,9	Niño 3	4,0	Niño 3	4,8	Niño 3.4	4,5
MLR	7	PSA2	3,0	SASAI	2,4	MEI	3,9	TSA	3,3	Niño 4	4,1
SVM	1	CPC	67,3	CPC	63,7	CPC	47,4	CPC	52,2	CPC	37,4
SVM	2	SEAS5	13,5	SEAS5	12,7	SEAS5	9,5	SEAS5	10,4	SEAS5	7,5
SVM	3	PSA1	4,1	RG2SSTI	4,8	Niño 1+2	4,3	PSA1	5,9	Niño 4	4,6
SVM	4	TNA	3,4	TNA	3,2	Niño 3	4,2	TSA	3,2	Niño 3.4	4,2
SVM	5	RG2SSTI	3,0	PSA1	1,7	BEST	3,9	Niño 3	3,0	RG2SSTI	4,0
SVM	6	SAODI	2,6	SASAI	1,5	SOI	3,8	Niño 3.4	2,9	ONI	4,0
SVM	7	SASDI	1,0	Niño 1+2	1,5	Niño 3.4	3,8	SASDI	2,7	BEST	3,8

regiões. Em particular, as anomalias de precipitação do CPC se destacam devido a sua substancial participação no conjunto de dados de entrada de ambos os modelos. Esse padrão indica a existência de autocorrelação nas séries temporais de anomalias de precipitação, uma característica altamente relevante para os modelos orientados por dados.

No que diz respeito aos índices climáticos, existem variações regionais notáveis naqueles que são comumente utilizados. Nas regiões SE e CO, os índices RG2SSTI, TNA e PSA1, derivados das anomalias de temperatura da superfície do mar no Oceano Atlântico e das anomalias de altura geopotencial a 700 hPa, são frequentemente empregados pelos modelos. No caso da região NE, os modelos dependem não apenas do PSA1 e dos índices do Oceano Atlântico (SASDI, TSA e RG2SSTI) mas também incluem um número substancial de índices associados ao ENSO (El Niño – South Oscillation), especificamente Niño 3 e Niño 3.4. Esse padrão é ainda mais acentuado na região S, onde índices como Niño 1+2, Niño 3, Niño 3.4, BEST e SOI prevalecem. Na região N, os modelos apresentam similarmente uma seleção de índices que inclui ONI, Niño 3.4, Niño 4 e BEST.

A integração frequente de índices climáticos de larga escala provenientes tanto dos oceanos Pacífico quanto Atlântico ressalta o papel essencial das condições oceânicas na previsão da precipitação sazonal. No Pacífico, fenômenos bem estudados como o El Niño e a La Niña exercem um impacto significativo na chuva das regiões S, NE e N, sendo o ENSO considerado um dos padrões mais influentes na América do Sul [113]. Por outro lado, no Atlântico, as anomalias de temperatura da superfície do mar e os dipolos oceânicos influenciam o posicionamento da Zona de Convergência Intertropical (ITCZ) [164], [165], [166], um componente chave que ajuda a moldar o regime de chuvas no NE.

### **3.3.3.5. *Framework de Data-driven Models***

A Figura 18 contempla uma visão geral das principais características do sistema de previsão sazonal de precipitação proposto nesta pesquisa. Nesse sistema, foram criados modelos estatísticos para cada célula de uma grade que abrange todo o Brasil, utilizando como *inputs* as séries temporais dos índices climáticos e as anomalias de precipitação do CPC e do SEAS5. Devido ao horizonte temporal de previsão ser de 7 meses, foi necessário construir modelos específicos para a previsão da anomalia de precipitação de cada mês levando em consideração o trimestre ao qual ele pertence. Portanto, 28 modelos estatísticos (4 trimestres x 7 meses) foram criados para cada célula. Dessa forma, a previsão de precipitação para um determinado mês é computada

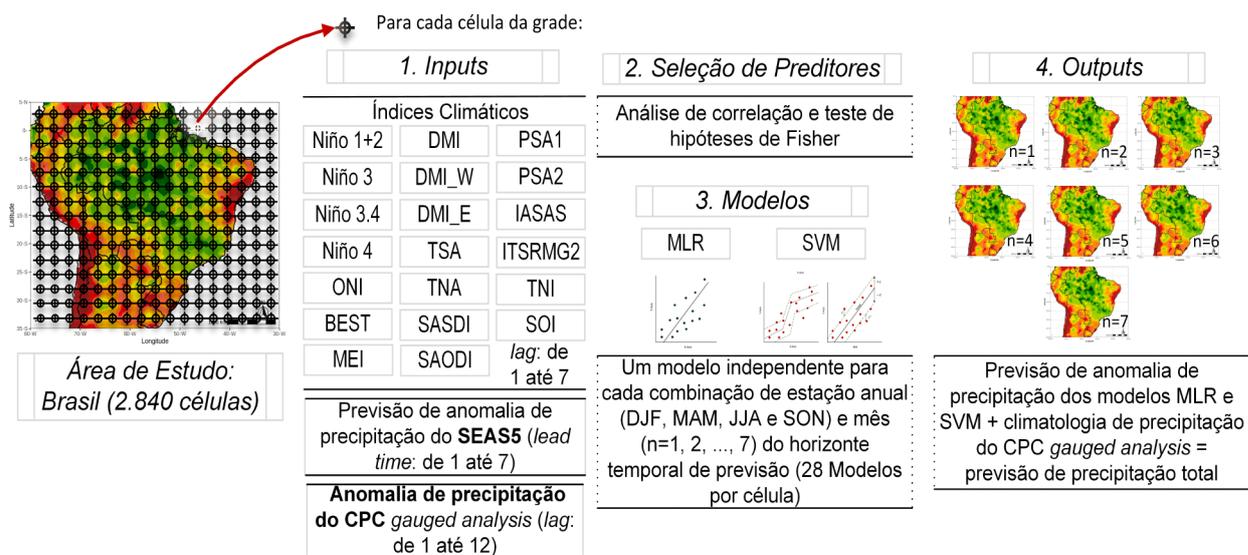


Figura 18 - Modelos estatísticos de previsão sazonal de precipitação. A imagem apresenta o conjunto de *inputs* e *outputs* dos modelos estatísticos implementados (MLR e SVM) para cada célula de uma grade sobre a região de interesse e por trimestre (MAM, JJA, SON e DJF).

através de um processo de reconstituição feito utilizando as previsões de anomalia e a climatologia mensal de precipitação calculada com dados do CPC de jan-1993 a dez-2016.

### 3.3.3.6. Simulação de Validação e Métricas de Avaliação

O período que inicia em jan-2017 e termina em dez-2020 foi utilizado para a realização das simulações de validação dos modelos MLR e SVM. Esse intervalo temporal foi escolhido por coincidir com período em que há dados de *forecast* do SEAS5, que possibilita a comparação dos modelos propostos com o modelo dinâmico. Os modelos SVM e MLR foram executados mensalmente, gerando ao término de cada execução previsões sazonais de precipitação para um horizonte temporal de 7 meses. As previsões de precipitação foram segregadas conforme o mês “n” (mês 1 a 7 do horizonte temporal de previsão), formando 7 conjuntos de dados. Esse tipo de segregação se justifica pelo fato de que é esperado que as previsões feitas para os primeiros meses do horizonte de 7 meses sejam mais acuradas. Além disso, é relevante mensurar como a qualidade delas decai ao longo do horizonte temporal de previsão. Posteriormente a esse processo, os dados de cada um dos 7 grupos foram segregados por trimestre (MAM, JJA, SON e DJF) sem comprometer a individualidade de cada mês. Para facilitar o entendimento da metodologia, a Figura 19 mostra como os dados das execuções inicializadas nos meses de janeiro de 2017 a dezembro de 2020 seriam segregados para o mês n do horizonte temporal de previsão e trimestre.



Figura 19 - Segregação das previsões sazonais de precipitação de acordo com o mês do horizonte temporal de previsão ( $n = 1, 2, \dots, 7$ ) e os trimestres MAM, JJA, SON e DJF. Na imagem é apresentado, como exemplo ilustrativo, o procedimento de segregação por estação anual das previsões do conjunto em que  $n = 5$ .

Os conjuntos de dados gerados através da aplicação do procedimento descrito anteriormente, em que os dados são reagrupados de acordo com o mês  $n$  ( $n = 1, 2, \dots, 7$ ) e o trimestre (MAM, JJA, SON e DJF), foram avaliados utilizando 2 métricas, o *Mean Absolute Error* (MAE) e o *bias*, bem como o Teste de Hipóteses de Diebold-Mariano. A definição de cada métrica está disponível na Tabela 5.

Tabela 5 - Métricas de avaliação e teste de hipóteses.

Métrica	Detalhes	Equação
<i>Mean Absolute Error</i> (MAE)	O MAE [189] mede a acurácia de um modelo ( <i>i.e.</i> , proximidade entre o valor previsto e o valor real) por meio do cálculo da média dos erros absolutos de um conjunto de previsões. Por ser uma estatística que faz a comparação direta entre previsões e dados observados, o ideal é que seu valor esteja sempre próximo de zero.	$MAE = \frac{1}{T} \sum_{t=1}^T  x_{m,t} - y_t  \quad (18)$ <p><math>x_{m,t}</math>: previsão feita pelo modelo <math>m</math> no tempo <math>t</math>; <math>y_t</math>: valor observado no tempo <math>t</math>.</p>

<i>Bias</i>	O <i>bias</i> [190] é uma métrica que mede o desvio médio entre duas séries de dados formadas por valores previstos e observados de uma mesma variável. Por não considerar o valor absoluto dos erros, como ocorre no caso do MAE, o <i>bias</i> consegue indicar se há uma tendência do modelo preditivo sobestimar ( <i>i.e.</i> , <i>bias</i> positivo) ou subestimar ( <i>i.e.</i> , <i>bias</i> negativo) as previsões. Portanto, o ideal é que ele esteja sempre próximo de zero. Além disso, é importante destacar que o <i>bias</i> deve ser analisado com prudência, pois pares de dados com erros de sinais opostos e mesma magnitude podem se cancelar, conforme mostra a sua expressão matemática.	$bias = \frac{1}{T} \sum_{t=1}^T (x_{m,t} - y_t) \quad (19)$ <p><math>x_{m,t}</math>: previsão feita pelo modelo <math>m</math> no tempo <math>t</math>; <math>y_t</math>: valor observado no tempo <math>t</math>.</p>
-------------	--	---

Diebold-  
Mariano  
Test  
(DMT)

O DMT é um teste de hipótese amplamente utilizado para a comparação da acurácia preditiva de duas séries temporais, A e B. As séries temporais de erro absoluto (ou quadrático),  $loss(e_{A,t})$  e  $loss(e_{B,t})$ , são comparadas ao longo do eixo do tempo pela função de perda diferencial  $d_t = loss(e_{A,t}) - loss(e_{B,t})$ . Se a expectativa de  $d_t$  for zero, A e B possuem o mesmo nível de acurácia preditiva (hipótese nula  $H_0$ ); caso contrário, uma delas é mais acurada que a outra (hipótese alternativa  $H_a$ ). O resultado de tal teste é fornecido pela análise do  $p$ -value, uma probabilidade baseada na função de distribuição acumulada da estatística DMT, conforme indicado em (20). Se o  $p$ -value for menor (maior) que o nível de significância  $\alpha$ ,  $H_0$  é rejeitada ( $H_0$  é aceita) e  $H_a$  é aceita ( $H_a$  é rejeitada).

$$\begin{aligned} H_0: E(d_t) &= 0 \\ H_a: E(d_t) &\neq 0 \\ DMT_{calc} &= \frac{\bar{d}}{\sqrt{\frac{\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k}{n}}} \quad (20) \\ p\text{-value} &= 2 \times \\ &[1 - CDF(DMT_{calc})] \end{aligned}$$

$CDF$  é a função de distribuição acumulada da estatística DMT;  $h$  é o horizonte de previsão;  $\gamma_k$  é a autocovariância de  $d$  considerando a lag  $k$ ;  $n$  é o número total de dados de cada série temporal; e  $\bar{d}$  é o valor médio da função de perda diferencial.

A autora desta tese de doutorado foi responsável por toda a implementação dos modelos MLR e SVM, pela condução das simulações de *backtest*, e pela análise detalhada dos resultados obtidos ao longo do estudo. Todos esses processos foram desenvolvidos utilizando a linguagem de programação R.

## 3.4. RESULTADOS E DISCUSSÃO

### 3.4.1. SEAS5 HINDCAST (jan-1993 a dez-2016)

Na Figura 20, são apresentados os resultados da aplicação das métricas de avaliação às séries temporais de todas as células da grade sobre as regiões de interesse para o trimestre DJF e mês  $n$  (apenas 1, 3 e 7, por brevidade). O objetivo do conjunto de mapas é mostrar em quais setores do Brasil o modelo SEAS5 apresenta maior ou menor acurácia em suas previsões de precipitação no trimestre DJF. Os mapas indicam que os maiores MAEs são observados na região onde se manifesta a Zona de Convergência do Atlântico Sul (ZCAS), que inicia na região amazônica em direção ao sudeste brasileiro (*i.e.*, engloba as regiões N, CO, SE do Brasil e parte do Oceano Atlântico). A ZCAS é um sistema meteorológico caracterizado pela formação de uma banda de nebulosidade e chuva quando sistemas frontais estacionários (com duração maior que 3 dias) interagem com a convecção tropical [191]. Uma das principais características da ZCAS é que ela gera um total de chuvas acentuado quando ativa, o que a torna um sistema extremamente importante para a estação chuvosa das regiões SE e CO. Quanto às demais regiões, S e NE, as previsões do SEAS5 são mais acuradas que do restante do Brasil, com destaque para a região NE onde são verificados os menores valores de MAE. Conforme o mês do horizonte temporal de

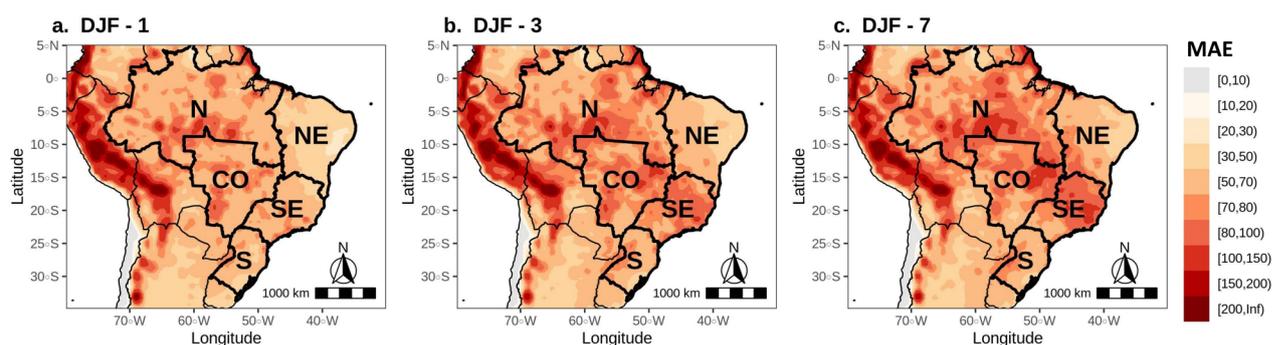


Figura 20 - MAE [mm/mês] das previsões sazonais de precipitação realizadas pelo SEAS5 nos trimestres DJF. Nessa avaliação, os dados de precipitação total do *hindcast* (jan-1993 a dez-2016) foram acumulados mensalmente e segregados por mês do horizonte temporal de previsão (meses 1, 3 e 7), respectivamente.

previsão muda de 1 para 7, os erros observados em todas as regiões ficam mais intensos, indicando uma queda relevante da acurácia do modelo quando a previsão é feita com maior antecedência, principalmente no caso do SE. Essa característica do SEAS5 pode ser identificada com maior facilidade através dos resultados apresentados na Tabela 6, que correspondem às médias dos valores calculados para a estatística MAE para o conjunto de células internas a cada região.

A segunda métrica de avaliação aplicada nesse estudo tem seus resultados apresentados na Figura 21. O objetivo do conjunto de mapas é revelar os setores do Brasil em que o modelo SEAS5 subestima ou sobrestima a precipitação total acumulada por mês. No período chuvoso, o SEAS5 apresenta *bias* positivo nas regiões S, SE e na maior parte do CO e N, com destaque para as regiões onde a ZCAS atua. Esse resultado indica que o modelo apresenta uma tendência de sobrestimar a precipitação nessas regiões. Quanto aos setores leste do N e norte do CO, o *bias* apresenta sinal negativo, indicando a subestimação da precipitação. Já no caso do NE do Brasil, o sinal do *bias* tende a variar de acordo com mês do horizonte temporal de previsão, podendo ser predominantemente negativo, como observado na Figura 21 b., ou positivo, Figura 21 c. Os resultados na Tabela 6 corroboram os resultados observados nos mapas, e ainda evidenciam que as regiões SE, CO e N apresentam um aumento quase contínuo do *bias* positivo conforme o mês do horizonte temporal de previsão muda de 1 para 7, com destaque para o SE e CO que atingem os maiores valores de enviesamento médio.

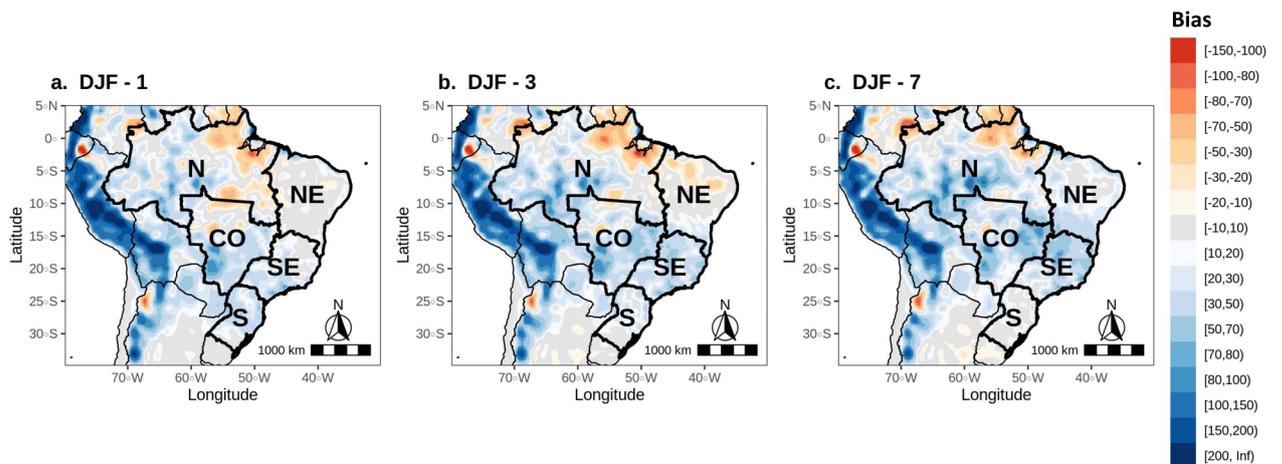


Figura 21 - *Bias* [mm/mês] das previsões sazonais de precipitação realizadas pelo SEAS5 no trimestre DJF. Nessa avaliação, os dados de precipitação total do *hindcast* (jan-1993 a dez-2016) foram acumulados mensalmente e segregados por mês do horizonte temporal de previsão (meses 1, 3 e 7), respectivamente.

Os resultados observados se assemelham aos de Gubler *et al.* [192], que foi o primeiro estudo a investigar a performance das previsões de temperatura e precipitação do modelo dinâmico SEAS5 na América do Sul nos trimestres MAM, JJA, SON e DJF utilizando dados de estações pluviométricas de medição como *ground truth*. Apesar da previsão de precipitação ser difícil de realizar (*i.e.*, por motivos tais como sua natureza intermitente, a formação da chuva depender fortemente de fatores locais e não existirem equações próprias para essa variável climática) o SEAS5 apresenta performance elevada nas regiões NE e S do Brasil, que são regiões em que o fenômeno El Niño - Southern Oscillation tem forte influência sobre a variabilidade da precipitação. Esse resultado sugere que o SEAS5 é capaz de capturar a influência do principal padrão de teleconexão que atua sobre a precipitação do Brasil. No caso do oeste da Amazônia e nos demais setores extratropicais do Brasil, desconsiderando o S, a performance das previsões de precipitação do SEAS5 é baixa de acordo com Gubler *et al.* [192], resultado que foi novamente validado no estudo apresentado nesta seção.

Tabela 6 - Sumário da média das métricas MAE [mm/mês] e *bias* [mm/mês] calculadas com a precipitação do SEAS5 (jan-1993 a dez-2016) para o trimestre DJF por região e mês do horizonte temporal de previsão.

	Mês do Horizonte Temporal de Previsão													
	1	2	3	4	5	6	7	1	2	3	4	5	6	7
Região	MAE							<i>Bias</i>						
S	58,79	62,71	62,71	63,01	61,36	62,26	62,55	24,70	11,94	13,97	12,75	5,30	4,34	4,17
SE	62,73	80,12	79,08	80,03	83,67	84,51	84,51	20,06	33,20	35,33	34,70	39,70	38,24	38,74
N	69,06	76,19	75,84	76,69	76,83	78,51	79,55	8,64	11,25	12,38	14,40	16,67	17,21	21,97
NE	43,93	54,86	54,48	57,10	58,37	59,54	61,79	3,65	1,05	-0,25	1,21	6,47	12,06	21,34
CO	69,35	77,62	77,42	76,70	78,81	79,96	78,87	22,55	32,74	34,30	32,91	36,50	36,51	36,55

Com a análise das previsões sazonais de precipitação do modelo SEAS5, observou-se que o desempenho do modelo dinâmico apresenta limitações nas regiões N, CO e SE durante o período de chuvas mais intensas. Diante disso, justifica-se a necessidade de desenvolver novos modelos que sejam capazes de aprimorar as previsões de precipitação no Brasil utilizando os dados disponibilizados pelos diversos centros de pesquisa climática.

### 3.4.2. PERFORMANCE DOS MODELOS MLR E SVM NO TRIMESTRE DJF (jan-2017 a dez-2020)

Na Seção 3.3.3, foram propostos dois modelos, MLR e SVM, para a previsão sazonal de precipitação utilizando os índices climáticos, os dados do CPC e do SEAS5 como preditores. Nesta seção, serão apresentados os resultados da avaliação feita com as previsões obtidas na simulação de validação, realizada para o período de jan-2017 até dez-2020, utilizando as métricas MAE e *bias*. O principal objetivo dessa avaliação é verificar a qualidade das previsões feitas pelos modelos propostos para o trimestre DJF e compará-las com o SEAS5, de modo a determinar qual deles apresenta melhor desempenho no período em questão.

A distribuição espacial dos MAEs calculados com as previsões feitas pelos modelos estatísticos (MLR e SVM) e pelo SEAS5 é apresentada na Figura 22. Os mapas revelam que as regiões NE e S do Brasil estão associadas aos menores valores de MAE, sem uma diferença aparente de performance entre os 3 modelos. Os resultados sugerem que nas regiões cuja variabilidade sazonal da precipitação é altamente dependente do ENSO, a aplicação dos modelos estatísticos não impacta expressivamente a acurácia das previsões. Esse resultado pode ser justificado pelo fato de o SEAS5 já possuir uma capacidade elevada em prever a precipitação nessas regiões que é, portanto, transferida para os modelos estatísticos. Já no caso das regiões SE,

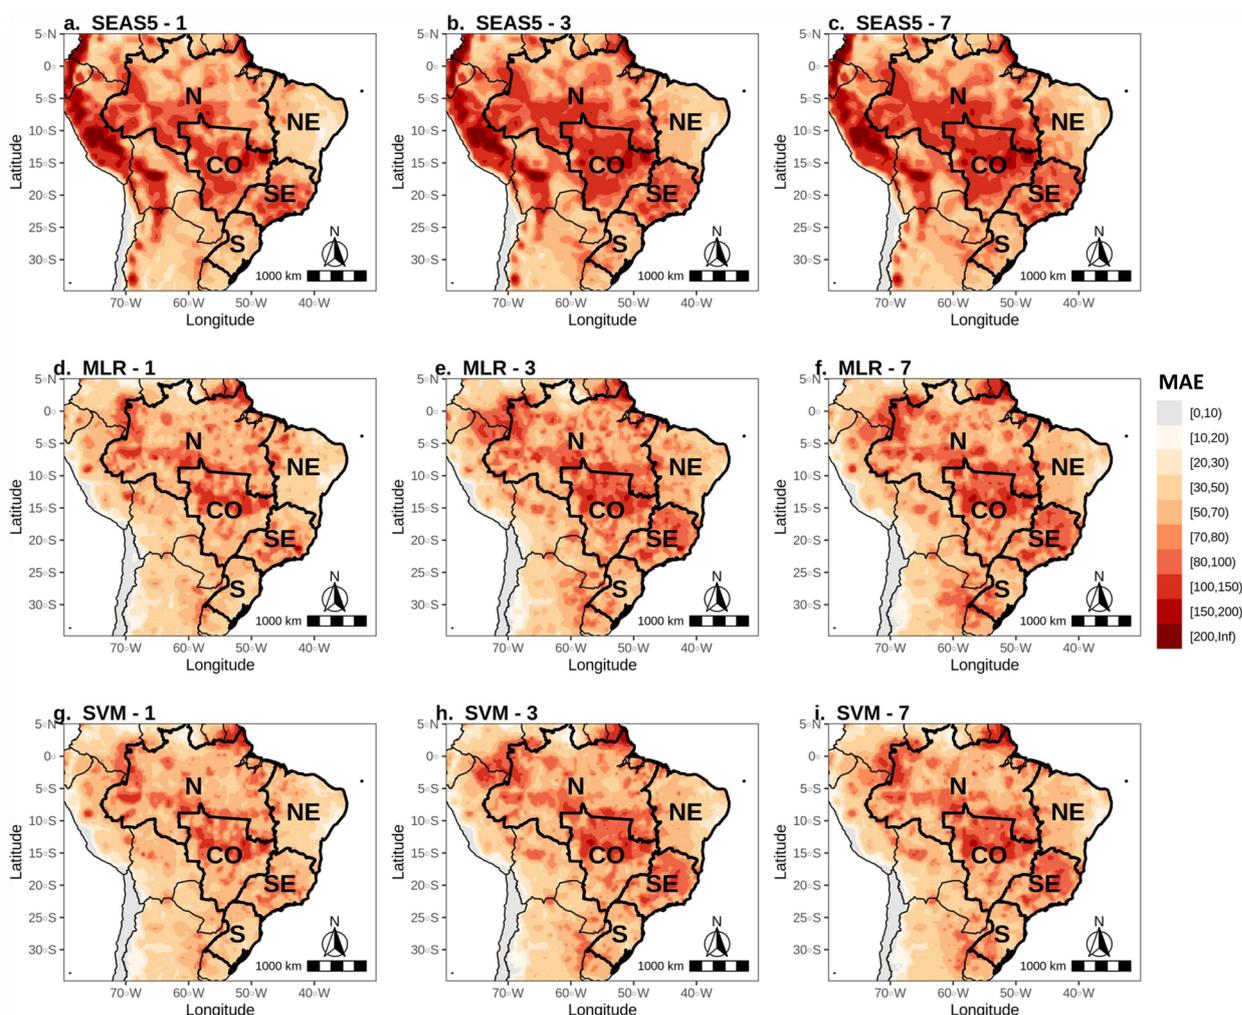


Figura 22 - MAE [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para o trimestre DJF. Os resultados da simulação de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7) e o trimestre DJF.

CO e N, a diferença de performance com relação ao SEAS5 é mais evidente. O modelo dinâmico do ECMWF continua apresentando o mesmo padrão de erros observado na avaliação feita para o período de *hindcast* (jan-1993 a dez-2016), só que com maior intensidade. Enquanto isso, os modelos estatísticos apresentam uma redução elevada dos MAEs calculados. Esse resultado indica que a aplicação de técnicas de ML, independentemente de serem técnicas lineares ou não, é capaz de aumentar a acurácia das previsões sazonais de precipitação em boa parte do Brasil.

---

Na Figura 23, são apresentados sete conjuntos de boxplots com os resultados relativos ao trimestre DJF. Cada boxplot é composto pelos MAEs calculados com as previsões feitas pelos modelos MLR, SVM e SEAS5 para o conjunto de células da grade que cobre a região estudada, enquanto os sete grupos definidos por  $n = 1, 2, \dots, 6, 7$  representam os meses do horizonte temporal de previsão. Os resultados indicam que os modelos MLR e SVM apresentam um erro médio inferior ao calculado para o SEAS5 nas regiões N, SE, CO e S em todos os 7 meses do horizonte temporal de previsão (exceto o MLR no S, quando  $n = 7$ ), com destaque para o CO onde os modelos propostos superam o SEAS5 com maior intensidade. No caso específico da região S, a diferença de performance entre os modelos não é tão expressiva quanto aquela observada para o caso das outras 3 regiões citadas. Já no NE, o modelo MLR não conseguiu superar o SEAS5, apresentando MAE médio superior ao calculado para o modelo dinâmico. Quando é avaliado o desempenho geral dos modelos (*i.e.*, em todas as regiões e meses do horizonte temporal de previsão), nota-se que a SVM gera as previsões de precipitação mais acuradas. Esse resultado sugere a existência de uma relação não linear entre a precipitação e os preditores que é capturada pela SVM. A efetividade de modelos não lineares em problemas de previsão de precipitação sazonal já foi atestada em vários estudos [126], [193], [194], [195]. No entanto, a aplicação de um modelo desse tipo não garante previsões acuradas, outro fator importante que deve ser considerado são os preditores utilizados, que devem explicar parte da precipitação observada sobre uma região. No estudo apresentado nesse capítulo, foram escolhidos índices climáticos associados aos padrões de teleconexão que influenciam a precipitação de algumas regiões do Brasil. Além disso, também foi explorada a relação existente entre a precipitação com os valores observados em meses anteriores (*i.e.*, autocorrelação da precipitação).

---

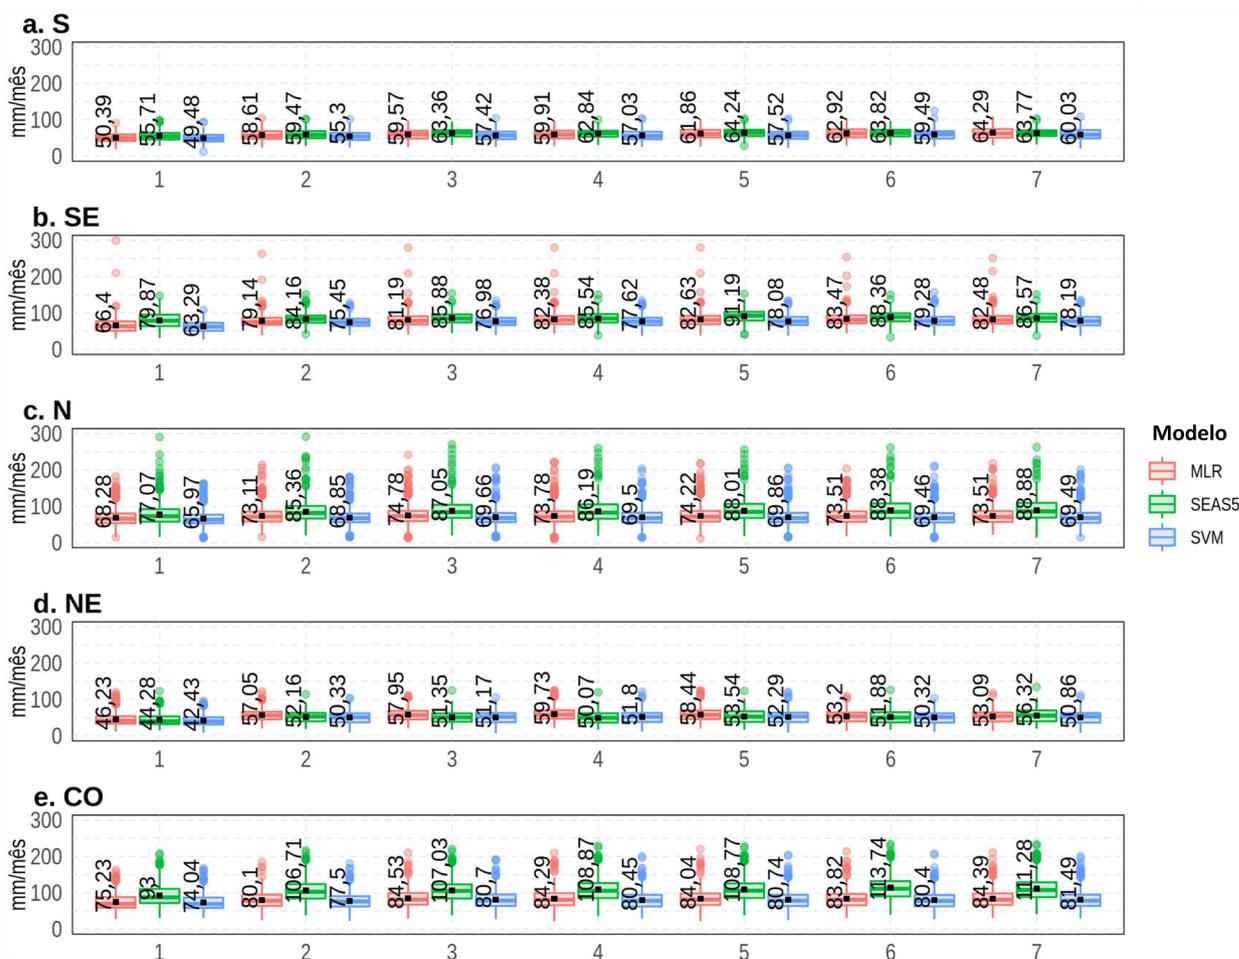


Figura 23 - Boxplots gerados com os MAEs [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para todas as células de uma grade sobre as regiões S, SE, N, NE e CO no trimestre DJF. Os resultados da simulação de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7).

A segunda métrica de avaliação aplicada nesse estudo tem sua distribuição espacial apresentada na Figura 24. Os mapas relacionados ao modelo SEAS5 indicam a existência de um *bias* positivo intenso nas regiões N, CO e SE do Brasil, o que revela uma tendência sistemática de sobrestimação da precipitação no verão austral. Esse resultado concorda com o obtido para o período de *hindcast* (jan-1993 a dez-2016). Entretanto, é notável o fortalecimento do enviesamento positivo das previsões de precipitação no período de *forecast* (jan-2017 a dez-2020) quando comparado ao *hindcast*. Os resultados sugerem que o SEAS5 pode estar aumentando a frequência ou intensidade de ocorrência de ZCAS no trimestre DJF, o que explicaria nos valores elevados de viés nas regiões N, CO e SE (*i.e.*, regiões onde a ZCAS costuma agir). No caso dos modelos MLR e SVM, em comparação ao SEAS5, ocorre uma redução generalizada do viés positivo nessas

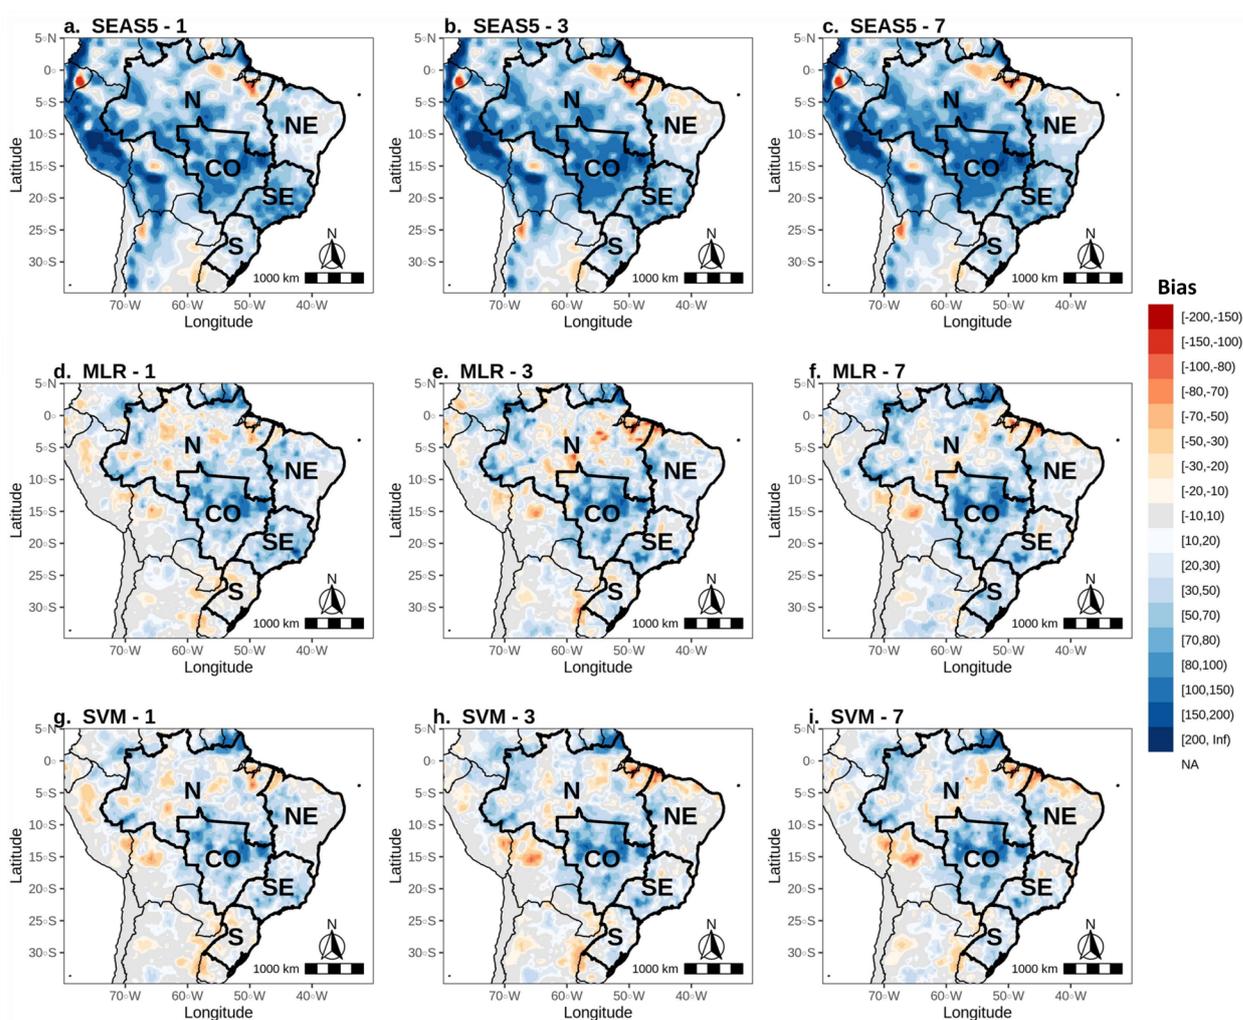


Figura 24 - *Bias* [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos MLR, SVM e SEAS5 para o trimestre DJF. Os resultados das execuções de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7) e o trimestre DJF.

mesmas regiões, com destaque para o N em que condições neutras de *bias* predominam. No NE e S, os modelos estatísticos e o SEAS5 também apresentam majoritariamente vieses positivos, só que bem menos intensos que os valores observados nas outras regiões.

Os boxplots da Figura 25 corroboram os resultados apresentados nos mapas e revelam novas informações sobre o enviesamento dos modelos. Em todas as regiões do Brasil, a MLR e a SVM conseguem reduzir o *bias*. Em especial, as regiões SE, CO e N foram as mais beneficiadas pela aplicação dos modelos propostos. Contudo, observa-se que no SE e S existe uma tendência de crescimento do *bias* médio conforme o mês do horizonte temporal de previsão vai de 1 a 7. Quando os resultados são comparados entre si, a SVM se destaca como sendo capaz de gerar as previsões menos enviesadas entre todos os modelos.

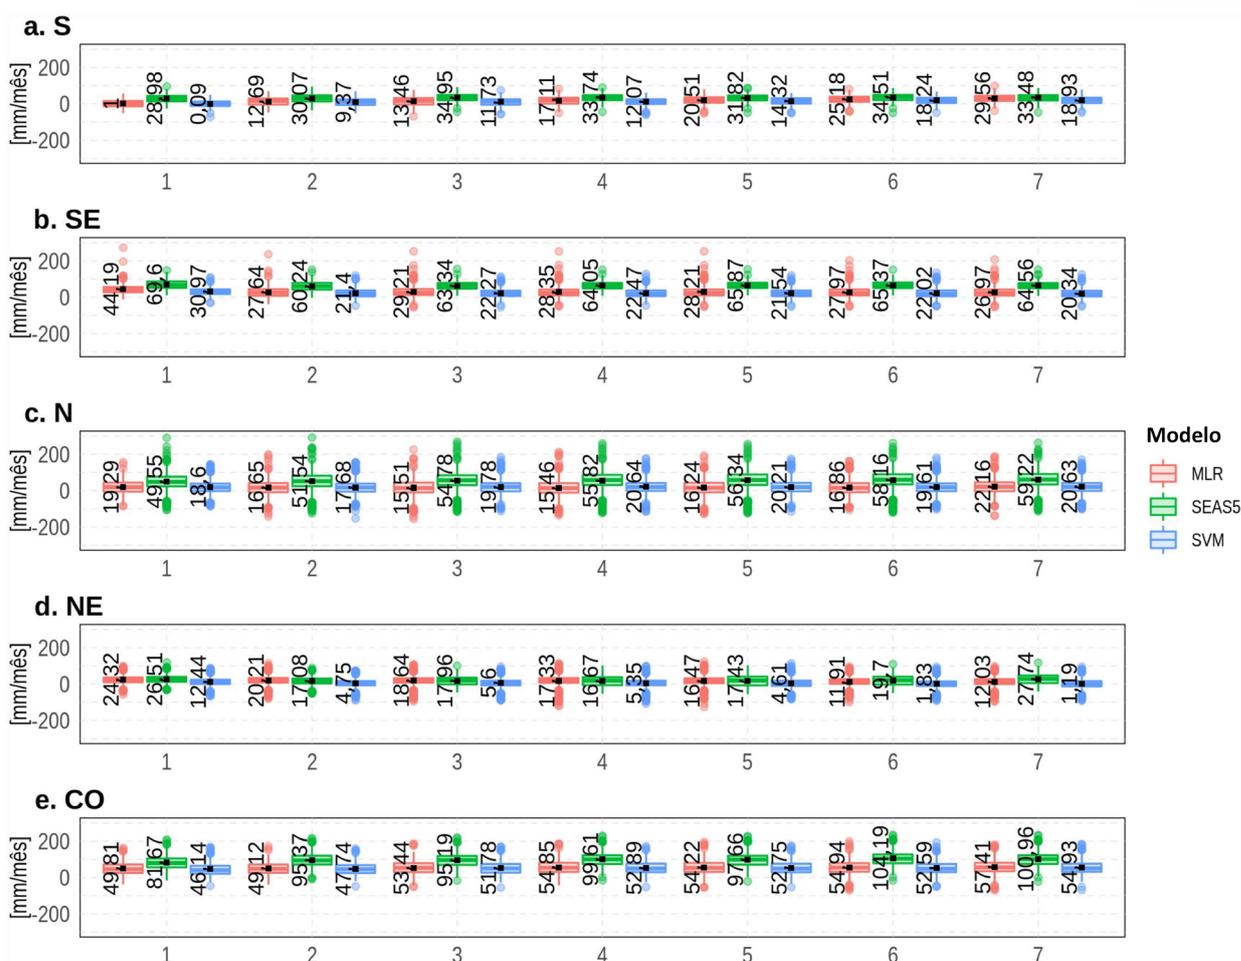


Figura 25 - Boxplots gerados com os *biases* [mm/mês] das previsões sazonais de precipitação realizadas pelos modelos estatísticos (MLR e SVM) e pelo SEAS5 para todos os pontos de grade da região estudada no trimestre DJF. Os resultados das execuções de validação (jan-2017 a dez-2020) foram segregados conforme o mês do horizonte temporal de previsão (meses 1, 2, ..., 7).

### 3.4.3. PERFORMANCE GERAL DOS MODELOS MLR E SVM (jan-2017 a dez-2020)

As séries temporais de precipitação do CPC e dos modelos MLR, SVM e SEAS5 são apresentadas na Figura 26 considerando os meses dos trimestres DJF, MAM, JJA e SON. Cada série é a média da precipitação associada aos pontos de grade internos às regiões N, NE, SE, CO e S. Os gráficos da figura indicam que, de forma geral, os três modelos conseguem representar o regime de precipitação do Brasil. As regiões N, NE, CO e SE possuem curvas com formato bem definido em que é possível identificar facilmente os meses do período chuvoso (meados de outubro a abril) e seco (restante dos meses) brasileiro, enquanto no caso do S a distribuição das chuvas não é tão bem definida ao longo do ano. No período chuvoso do N, SE e CO, as previsões do SEAS5

costumam estar acima dos valores registrados pelo CPC; resultado concordante com aquele obtido nos mapas a., b. e c. da Figura 24 em que é verificado um intenso *bias* positivo nessas regiões. Já os modelos MLR e SVM apresentam curvas mais aderentes às curvas do CPC, indicando uma capacidade preditiva superior. Ao longo do período seco, todos os modelos geram previsões próximas à precipitação do CPC, com exceção do SEAS5 no N, que costuma sobrestimar a precipitação. No caso específico da região S, existe uma certa dificuldade generalizada na representação da variabilidade mensal da precipitação independente da estação anual, o que ressalta a complexibilidade em realizar previsões devido a precipitação depender da ocorrência dos transientes de alta frequência [137].

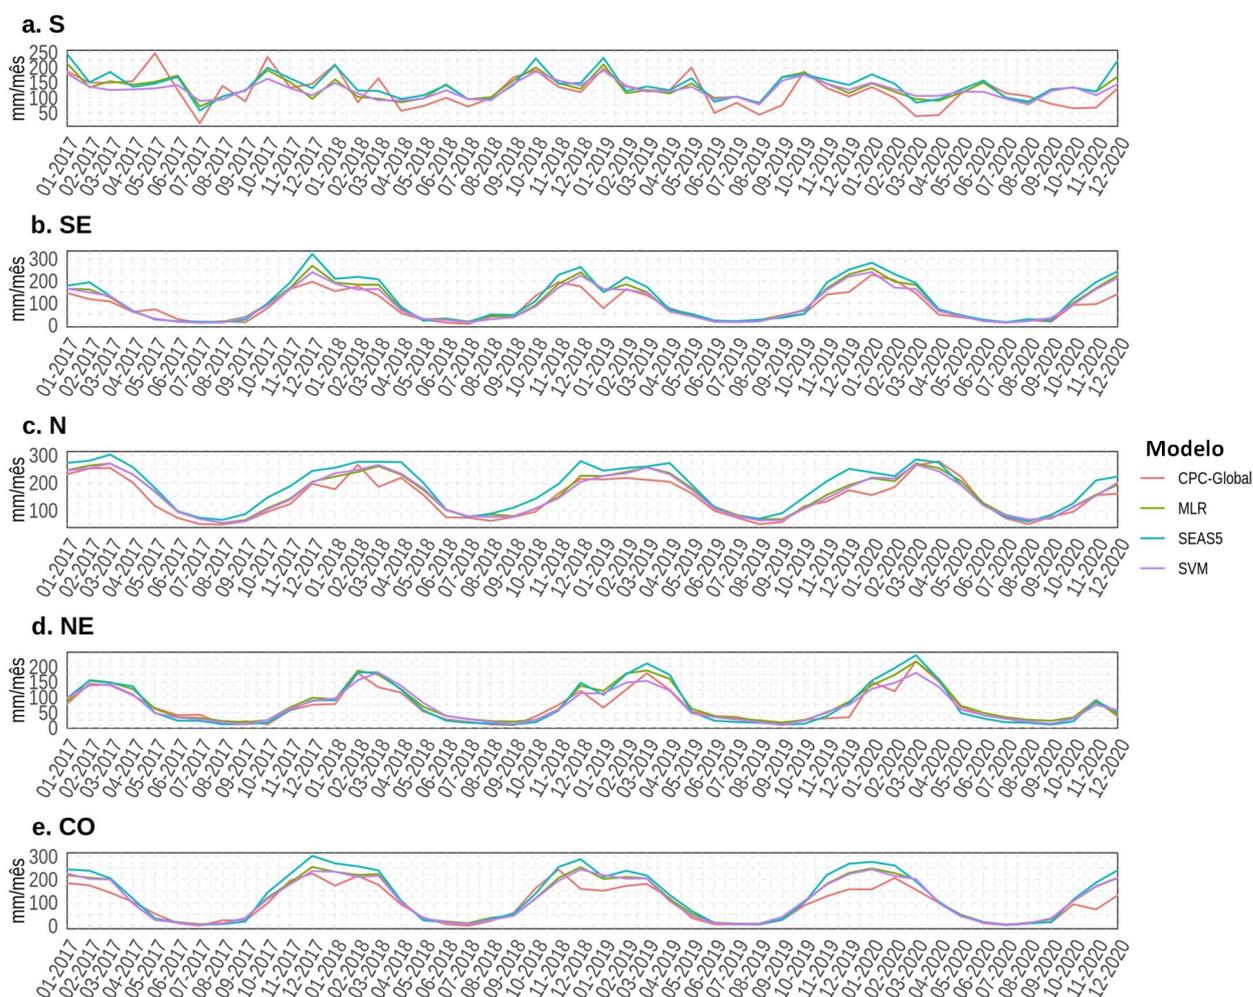


Figura 26 - Séries temporais das previsões de precipitação feitas pelos modelos MLR, SVM e SEAS5 (para o mês  $n = 1$  do horizonte temporal de previsão) de jan-2017 até dez-2020. Os dados foram computados para cada região do Brasil por meio do cálculo da média da precipitação associada às células internas a cada região.

A Figura 27 ilustra o padrão espacial dos resultados da aplicação do Teste de Hipóteses Diebold-Mariano aos modelos SEAS5, MLR e SVM. O teste foi aplicado a fim de identificar as regiões do Brasil nas quais as previsões de um modelo específico são significativamente mais acuradas do que aquelas de um modelo concorrente. A análise leva em conta um horizonte de previsão de sete meses, com simulações inicializadas mensalmente (de janeiro de 2017 até dezembro de 2020) e incluindo todos os trimestres do ano (DJF, MAM, JJA e SON). Os mapas a. e b. da figura em questão mostram que ambos os modelos MLR e SVM produzem previsões de precipitação mais acuradas que as do SEAS5 nas regiões N, SE e CO. Isso é particularmente evidente para o caso do modelo SVM, que possui mais células de grade verdes no mapa b. Essas regiões são fortemente impactadas pela ZCAS durante o verão austral, sistema meteorológico responsável por grande parte da precipitação total observada em uma extensa faixa da América do Sul. Para as outras regiões, vale destacar que o modelo MLR geralmente produz previsões menos

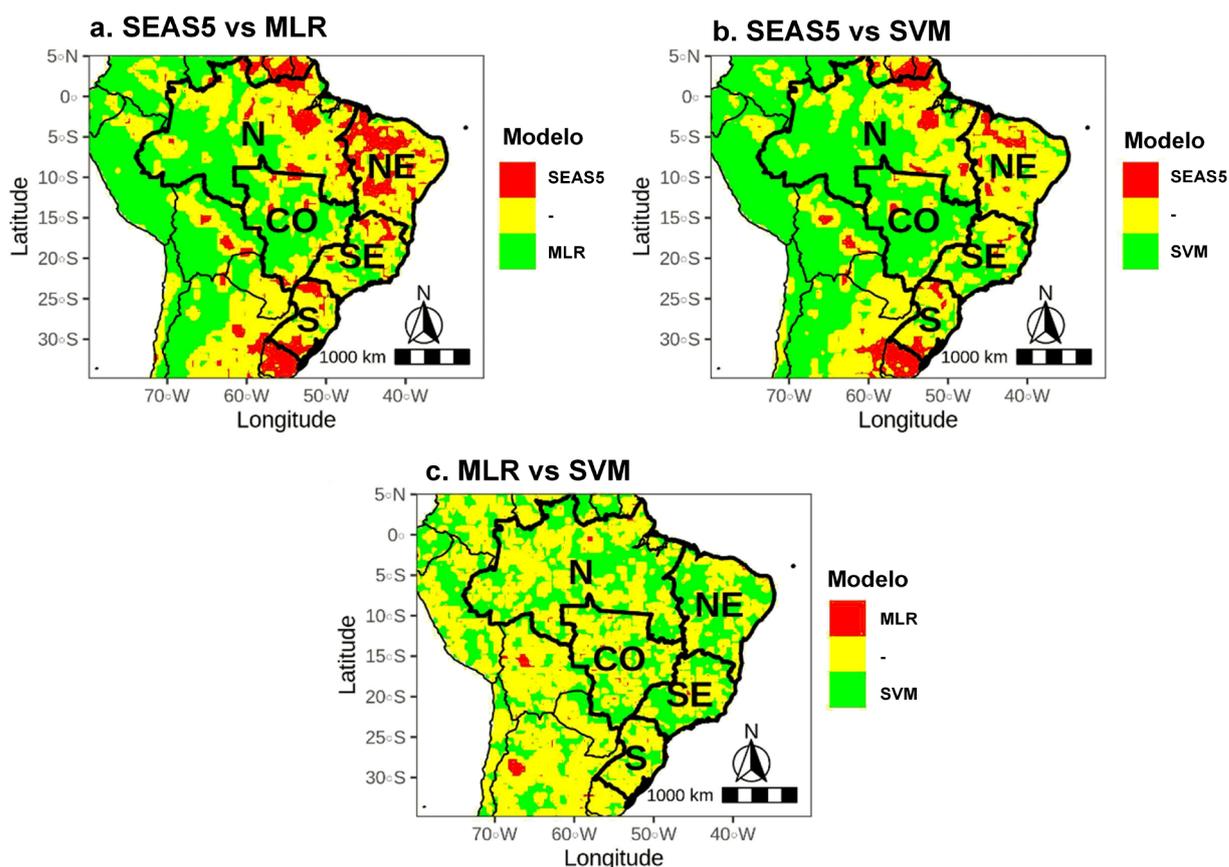


Figura 27 - Padrão espacial dos resultados obtidos por meio do Teste de Hipóteses de Diebold-Mariano, considerando um nível de significância  $\alpha$  de 0,05, um horizonte de previsão de sete meses à frente e as previsões mensais feitas de janeiro de 2017 a dezembro de 2020. O conjunto de mapas mostra, em cores, os setores do Brasil para os quais as previsões realizadas por um modelo específico são significativamente mais precisas do que as feitas pelo modelo concorrente.

---

acuradas que o SEAS5, enquanto as previsões do modelo SVM assemelham-se às geradas pelo sistema dinâmico ECMWF. Similarmente, na região Sul do Brasil, nenhum dos modelos se destaca de maneira particular, embora haja células de grade onde alguns modelos demonstram superioridade preditiva. Com relação ao mapa c. da Figura 27, que compara as previsões dos dois modelos propostos, observa-se um resultado distinto. O modelo SVM gera previsões significativamente mais acuradas em aproximadamente metade das células de grade do Brasil, destacadas em verde. Para as demais células de grade (coloridas em amarelo), não há diferença significativa no desempenho preditivo entre os modelos.

De forma geral, os resultados obtidos revelam que os modelos híbridos propostos neste estudo exibem acurácia superior à do SEAS5, principalmente nas regiões N, CO e SE. Modelos numéricos de previsão climática como o SEAS5, apesar de apresentarem a vantagem de suas equações possuírem uma interpretação física, sofrem com as incertezas relacionadas à fatores como condições de inicialização, parametrização e estrutura, que acabam afetando a performance de suas previsões. Já os modelos baseados em MLR e SVM, apesar de também estarem expostos à diversas fontes de incertezas, apresentam uma vantagem crucial sobre os modelos numéricos: a adaptabilidade a conjuntos de dados, que é caracterizada pela capacidade de identificar relações entre os *inputs* e *outputs*, permitindo, posteriormente, a aplicação dessas relações a novos dados de entrada a fim de realizar previsões. Essa questão se torna ainda mais vantajosa quando é utilizado um conjunto de preditores cuja relação é relevante, como ocorre no caso dos índices climáticos utilizados para o monitoramento de padrões de teleconexão que afetam a precipitação no Brasil [113]. Com relação aos modelos testados, os resultados obtidos revelam que o modelo baseado em SVM é capaz de gerar previsões mais acuradas que o MLR, o que sugere a existência de relações não lineares entre os preditores e a precipitação. De fato, modelos lineares sofrem de certas desvantagens, conforme mencionado anteriormente por Fan *et al.* [196], como a incapacidade de mapear dependências não lineares entre os preditores e a variável que está sendo prevista, o que resulta na perda dos componentes não lineares dessa relação no processo de modelagem. Em contrapartida, modelos orientados por dados baseados em abordagens não lineares, como as SVMs implementadas aqui, não sofrem de tal deficiência e, conseqüentemente, são capazes de fornecer melhores previsões. Dessa forma, os trabalhos futuros devem focar na exploração de outras técnicas não lineares de *Machine Learning* junto ao aprimoramento da seleção/pré-processamento dos preditores.

---

### 3.5. CONCLUSÃO

Este estudo apresentou um novo *framework* baseado em *Multivariable Linear Regression* e *Support Vector Machine* para o aprimoramento das previsões sazonais de precipitação de 1 a 7 meses à frente, utilizando os índices climático associados aos padrões de teleconexão do Brasil, a análise de precipitação do CPC e dados do modelo SEAS5 como *inputs*. Os resultados indicam que os modelos propostos têm a capacidade de aumentar a acurácia das previsões de precipitação nas regiões brasileiras N, SE e CO. Entretanto, existe uma tendência de crescimento dos erros e *bias* positivo ao longo do horizonte temporal de previsão (*i.e.*, as previsões feitas para os primeiros meses desse horizonte tendem a ser mais acuradas que as feitas para os últimos meses). As regiões N, SE e CO correspondem à área de atuação da ZCAS, que é um dos principais sistemas atmosféricos causadores de precipitação no verão. O *bias* positivo observado nos resultados sugere que o SEAS5, e em menor grau os modelos MLR e SVM, tendem a aumentar a frequência ou a intensidade da ocorrência desse sistema.

As regiões NE e S se destacam das demais quando se trata da performance dos modelos. A acurácia das previsões de precipitação feitas pelo SEAS5 e pelos modelos estatísticos não difere muito, com exceção do modelo MLR que apresenta desempenho ruim no S. Apenas o modelo SVM consegue entregar uma performance melhor que a do SEAS5 tanto no S quanto no NE. A precipitação nesses setores está fortemente relacionada às fases do ENSO, que é uma das forçantes climáticas que mais afetam o Brasil via teleconexões climáticas. Tais resultados sugerem que o SEAS5 é capaz de representar o impacto desses modos de variabilidade nas suas previsões de precipitação, e essa capacidade é incorporada nos modelos MLR e SVM.

Quando os modelos são comparados entre si, observa-se que a SVM realiza previsões mais acuradas e menos enviesadas que o modelo concorrente. Esse resultado sugere a existência de relações não lineares entre os preditores e a precipitação prevista que não são capturadas pelo modelo MLR. No entanto, é importante ressaltar que a performance da SVM também se deve aos preditores que foram selecionados, pois eles possuem a capacidade de explicar parcialmente a precipitação. Em trabalhos futuros, objetiva-se investigar a aplicação de métodos de seleção de variáveis de entrada, decomposição das séries temporais dos preditores e a avaliação de outros modelos não lineares.

### 3.6. APÊNDICE

Tabela 7 - *Ranking* dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre MAM).

Modelos	Ranking	SE [320 células]		CO [542 células]		S [207 células]		NE [512 células]		N [1259 células]	
		Variável	%	Variável	%	Variável	%	Variável	%	Variável	%
		MLR	1	precCPC	41,7	precCPC	41,6	precCPC	29,5	precCPC	25,1
MLR	2	SEAS5	13,9	SEAS5	15,1	SEAS5	12,6	SEAS5	12,0	SEAS5	7,4
MLR	3	DMI	10,5	ITSRMG2	8,9	MEI	5,9	DMI	6,9	TNA	6,1
MLR	4	ITSRMG2	5,6	TNA	7,5	NINO12	5,7	NINO3	6,8	ITSRMG2	4,6
MLR	5	IASAS	3,6	DMI	4,8	PSA2	5,4	NINO34	5,3	PSA2	4,6
MLR	6	SAODI	2,5	TNI	3,1	NINO3	5,1	IASAS	5,1	NINO3	4,0
MLR	7	TNA	2,5	PSA1	2,7	ONI	4,9	SOI	4,7	BEST	3,6
SVM	1	precCPC	56,3	precCPC	60,9	precCPC	35,5	precCPC	34,5	precCPC	42,9
SVM	2	SEAS5	11,3	SEAS5	12,2	SEAS5	7,1	SEAS5	6,9	SEAS5	8,6
SVM	3	DMI	4,5	ITSRMG2	4,1	SOI	5,9	NINO3	4,9	NINO34	3,5
SVM	4	SOI	2,7	TNA	4,0	MEI	5,8	SOI	4,7	NINO3	3,5
SVM	5	TNA	2,7	DMI	2,9	NINO12	5,3	NINO34	4,6	ONI	3,3
SVM	6	ITSRMG2	2,5	NINO12	1,7	BEST	5,3	BEST	4,5	TNA	3,3
SVM	7	NINO12	2,1	NINO3	1,4	NINO3	4,8	DMI	4,4	BEST	3,3

Tabela 8 - *Ranking* dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre JJA).

Modelos	Ranking	SE [320 células]		CO [542 células]		S [207 células]		NE [512 células]		N [1259 células]	
		Variável	%	Variável	%	Variável	%	Variável	%	Variável	%
		MLR	1	precCPC	53,2	precCPC	54,9	precCPC	55,6	precCPC	31,5
MLR	2	SEAS5	12,7	SEAS5	13,0	SEAS5	9,0	TSA	6,9	SEAS5	9,7
MLR	3	PSA2	6,9	TNA	9,2	TNI	7,4	SEAS5	6,9	TNA	7,3
MLR	4	TNA	5,7	PSA2	3,3	NINO12	4,1	NINO12	4,9	ITSRMG2	7,1
MLR	5	DMI	4,2	DMI	3,2	PSA2	3,6	ONI	4,4	SASDI	4,1
MLR	6	TSA	3,3	IASAS	2,6	NINO3	3,3	ITSRMG2	4,1	NINO3	3,2
MLR	7	IASAS	2,9	TSA	2,3	PSA1	3,3	NINO34	4,0	NINO4	3,1
SVM	1	precCPC	64,7	precCPC	66,5	precCPC	59,3	precCPC	46,5	precCPC	51,7
SVM	2	SEAS5	12,9	SEAS5	13,3	SEAS5	11,9	SEAS5	9,3	SEAS5	10,3
SVM	3	TNA	4,6	TNA	5,0	NINO12	4,3	TSA	3,9	TNA	4,6
SVM	4	PSA2	3,7	DMI	1,5	NINO3	3,6	SAODI	3,8	ITSRMG2	3,4
SVM	5	DMI	2,3	TSA	1,5	TNI	3,6	NINO3	3,6	NINO34	2,9
SVM	6	TSA	1,6	IASAS	1,3	PSA1	2,9	NINO34	3,3	NINO4	2,7
SVM	7	IASAS	1,3	PSA2	1,3	MEI	2,3	NINO12	3,2	NINO3	2,7

Tabela 9 - *Ranking* dos principais preditores utilizados pelos modelos MLR e SVM para a previsão de precipitação sazonal no Brasil (apenas para o trimestre SON).

Modelos	Ranking	SE [320 células]		CO [542 células]		S [207 células]		NE [512 células]		N [1259 células]	
		Variável	%	Variável	%	Variável	%	Variável	%	Variável	%
MLR	1	precCPC	32,2	precCPC	42,0	precCPC	36,6	precCPC	24,2	precCPC	34,5
MLR	2	TNI	9,6	SEAS5	12,6	IASAS	14,5	SOI	10,8	SEAS5	9,4
MLR	3	SEAS5	7,7	TNI	5,0	SEAS5	9,5	SEAS5	8,1	ITSRMG2	7,0
MLR	4	SOI	5,4	ITSRMG2	4,9	ONI	6,2	PSA1	6,9	NINO4	5,9
MLR	5	BEST	4,5	IASAS	3,6	NINO34	5,5	ITSRMG2	6,9	NINO34	4,2
MLR	6	ONI	4,5	NINO4	3,3	BEST	4,5	BEST	6,2	NINO3	3,9
MLR	7	DMI	4,0	SOI	3,1	NINO3	4,0	NINO4	4,7	SASDI	3,5
SVM	1	precCPC	43,6	precCPC	54,0	precCPC	43,0	precCPC	43,8	precCPC	41,1
SVM	2	SEAS5	8,7	SEAS5	10,8	SEAS5	8,6	SEAS5	8,8	SEAS5	8,2
SVM	3	TNI	4,9	TSA	3,0	ONI	5,2	SOI	5,8	NINO4	4,9
SVM	4	SOI	4,7	MEI	2,7	BEST	5,1	BEST	5,4	ITSRMG2	4,4
SVM	5	BEST	4,3	NINO34	2,5	NINO34	5,1	NINO4	4,3	NINO34	4,1
SVM	6	MEI	4,1	NINO4	2,4	IASAS	5,1	NINO34	4,3	NINO3	4,0
SVM	7	NINO34	4,0	BEST	2,4	NINO3	5,0	ONI	4,2	ONI	3,6

---

# CAPÍTULO 4

## PREVISÃO DA CURVA FORWARD DE PREÇOS DA ENERGIA CONVENCIONAL USANDO REDES NEURAIAS ARTIFICIAIS

### 4.1. RESUMO

No Brasil, a comercialização bilateral de energia vem ganhando força ao longo dos últimos anos com a expansão do Ambiente de Comercialização Livre (ACL), onde geradores, grandes consumidores e comercializadores firmam contratos de venda e compra de energia convencional e incentivada considerando montantes de energia e prazos de entrega variados. Os agentes envolvidos acompanham diariamente o comportamento da *Curva Forward* de preços negociados e realizam estudos prospectivos com o intuito de antever a evolução temporal do mercado de energia para assim estabelecer estratégias que sejam lucrativas. Apesar da ampla aplicação de algoritmos de *Machine Learning* para a previsão de preços e seus movimentos em mercados de ações, cambio e criptomoedas, no Brasil, a abordagem desse problema no âmbito dos preços negociados no mercado livre de energia foi pouco explorada, principalmente usando arquiteturas mais avançadas de redes neurais. O objetivo deste estudo é explorar a aplicação de redes neurais artificiais na previsão da curva de preços dos contratos de energia convencional firmados no mercado livre de energia brasileiro, considerando produtos relacionados ao Submercado Sudoeste/Centro-Oeste (SE/CO) com maturidade de até 6 meses à frente. São avaliadas redes neurais do tipo Recorrente (RNN), *Multi-Layer Perceptron* (MLP), *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), considerando variações estruturais na arquitetura de cada uma delas, além da influência de preditores exógenos relacionadas à operação do Sistema Interligado Nacional (SIN) e do ACL, tais como Energia Natural Afluente aos aproveitamentos hidroelétricos do SIN, carga do Submercado SE/CO, nível de armazenamento dos reservatórios do Submercado SE/CO e o Preço de Liquidação das Diferenças do Submercado SE/CO. Os resultados mostram que a rede neural GRU apresenta a melhor performance preditiva em termos de acurácia, eficiência, concordância e correlação com os dados da série oficial de

---

---

preços, gerando ainda previsões estatisticamente mais acuradas que as das demais arquiteturas testadas. Apesar dos resultados obtidos com a GRU, experimentos adicionais mostram que a arquitetura LSTM foi capaz de superar a GRU quando se avalia o retorno financeiro acumulado por um agente comercialização que toma posições de compra e venda informadas pela rede neural sob análise.

## 4.2. CONTEXTUALIZAÇÃO

A previsão de preços e tendências em mercados de ativos tem ganhado notoriedade mundial nos últimos anos, devido à sua aplicabilidade na orientação da tomada de decisões de compra e venda. Vários são os setores da economia que exploram as soluções desenvolvidas nesse âmbito, como é o caso do mercado de câmbio, com a previsão de movimentos de preço para os pares USD/JPY e EUR/USD no *Foreign Exchange* [197], [198]; a previsão de tendências no preço de criptomoedas, tais como *Bitcoin*, *Etherium*, *Ripple* e *Litecoin* [199], [200], [201]; previsão da direção das ações de empresas da bolsa de valores dos Estados Unidos que compõem o *Standard and Poor's 500* [202]; e a previsão do preço da energia no Mercado Espanhol [203] e Irlandês [204]. Previsões do tipo auxiliam na tomada de decisões mais informadas por parte dos investidores, *traders*, analistas e gestores de portfólio, permitindo antecipar flutuações de preços e estruturar estratégias de compra e venda mais eficientes. Além de serem cruciais para a gestão de riscos, ao possibilitar ajustes nas carteiras de investimentos conforme a volatilidade do mercado, essas análises também são vitais para o planejamento estratégico de empresas e investidores institucionais, impactando diretamente a previsão de custos de matérias-primas e produtos. Adicionalmente, os *traders* que adotam modelos preditivos avançados conseguem vantagens competitivas, especialmente em operações de alta frequência, podendo melhorar a rentabilidade em vários tipos de mercado.

Neste contexto de previsão de preços e movimentos em mercados, a aplicação de técnicas de *Machine Learning* vem ganhando força ao longo dos últimos anos [205], [206], [207], [208]. O *modus operandi* desses algoritmos é fundamentado no aprendizado e reconhecimento de padrões a partir de grandes volumes de dados, como históricos de preços, indicadores econômicos, indicadores técnicos e outras séries temporais relevantes, desenvolvendo assim a habilidade de prever tendências de mercado. Diversas são as técnicas utilizadas, cada uma adequada a diferentes tipos de dados e objetivos. As principais incluem *Artificial Neural Networks* (ANNs), que são proficientes na modelagem de relações complexas e não lineares [199], [202]; *Support Vector*

---

---

*Machines (SVMs)*, eficazes em espaços de alta dimensão [202]; *Random Forest*, que ajudam a reduzir o *overfitting* [199], [204], [209]; métodos de ensemble, que combinam múltiplos modelos a fim de aumentar a robustez das previsões [210]; modelos estatísticos como *Autoregressive Integrated Moving Average (ARIMA)*, ideais para dados temporais [203]; e técnicas de *Deep Learning*, como *Recurrent Neural Networks*, para capturar padrões em dados sequenciais [198].

Na esfera do mercado livre de energia brasileiro – ambiente de comercialização de energia elétrica em que ocorre a livre negociação entre geradores, comercializadores, importadores e consumidores livres ou especiais – a aplicação de técnicas do tipo é ainda pouco explorada, apesar da expansão acelerada pela qual vem passando. Esse mercado tem demonstrado um crescimento expressivo tanto em volume de energia negociado quanto em número de agentes atuantes. Tal avanço é impulsionado por fatores como a liberalização progressiva do mercado, que amplia o acesso a consumidores de diversos portes [211], [212]; a atratividade econômica, com potenciais economias nos custos de energia; o fomento às fontes renováveis, beneficiadas por incentivos fiscais, tais como descontos nas tarifas de transmissão e distribuição; e ajustes regulatórios contínuos que adaptam o mercado às novas demandas e tecnologias. Juntos, esses elementos atraem investidores e consumidores, tornando o mercado livre de energia brasileiro cada vez mais amplo e importante, tornando ainda mais necessário o desenvolvimento de ferramentas que sejam capazes de auxiliar os agentes no entendimento da direção dos preços, para a tomada de decisões informadas.

#### 4.2.1. ESTUDOS RELACIONADOS

Com o objetivo de aprofundar o entendimento sobre a aplicabilidade de modelos de *Machine Learning* na previsão de preços e tendências, selecionou-se uma série de estudos recentes que exploram o tema. Estes estudos abrangem não apenas o mercado de energia, mas também os mercados de câmbio e de ações, oferecendo uma perspectiva multidisciplinar. Abordagem que permite uma compreensão mais apurada dos progressos alcançados com a aplicação diversas técnicas de *Machine Learning* em diferentes ambientes econômicos.

Neste contexto, Gerlein *et al.* (2016) [197] investigam e avaliam a utilização de algoritmos de *Machine Learning* de menor complexidade na tarefa de prever movimentos no valor do par de moedas USD/JPY no âmbito global do mercado de câmbio, também conhecido como FOREX (*Foreign Exchange*). A pesquisa foca na exploração de métodos computacionais simplificados na previsão de tendências de preço, contribuindo para uma compreensão mais

---

---

aprofundada sobre o desempenho de tais técnicas no contexto de negociações cambiais. O mercado FOREX estabelece-se como o mais expressivo mercado global de negociação de moedas, contando com uma diversidade de participantes que incluem desde bancos centrais até *traders* individuais. Ele desempenha um papel crucial ao facilitar a conversão de moedas para operações de comércio e investimentos em escala global. Apesar de sua função primordial ser a facilitação de transações internacionais, muitos participantes almejam obter lucro através da especulação sobre as flutuações cambiais, demonstrando o seu caráter multifacetado no contexto econômico mundial. Nesse contexto, Gerlein *et al.* busca determinar se métodos menos complexos são capazes de gerar resultados comerciais lucrativos e consistentes ao longo de períodos extensos. No estudo apresentado, foram utilizados seis algoritmos de mineração de dados (*Naïve Bayes*,  $K^*$ , *One Rule*, *C4.5*, *Logistic Model Tree* e o *Repeated Incremental Pruning to Produce Error Reduction*) para avaliar a capacidade de previsão financeira em uma arquitetura de mercado que inclui dois agentes: o Agente de Mercado, que codifica dados financeiros, e o Agente de Negociação, que processa os indicadores técnicos e usa um dos seis classificadores para prever tendências de preço, enviando ordens com base nessas previsões. Os modelos de *Machine Learning* utilizados preveem a direção do preço dos instrumentos financeiros, orientando se devem ser comprados ou vendidos no próximo período de negociação. Os resultados do estudo demonstram que modelos mais simples podem fomentar estratégias rentáveis no mercado FOREX, embora a lucratividade esteja atrelada a parâmetros específicos e ajustes dinâmicos frequentes (retreinamento do modelo com dados recentes e seleção de atributos). A seleção cuidadosa de atributos, oriundos de características de preço, sazonalidade e indicadores técnicos, é vital para otimizar o desempenho. Mesmo assim, as complexidades do mercado representam um desafio para a previsão exata das tendências de preço futuro. Apesar da rentabilidade, os modelos apresentam uma precisão moderada.

Shynkevich *et al.* (2017) [202] exploram a aplicação de indicadores técnicos e modelos de *Machine Learning* no problema de previsão de movimentos de preços das companhias que compõem o S&P 500 no mercado de ações, com foco na análise de como a performance de sistemas de previsão varia com a extensão da janela de dados de entrada e do horizonte de previsão. Neste estudo, os autores empregaram técnicas de SVMs, ANNs e *k-Nearest Neighbours* (kNN) para categorizar os movimentos de preços do mercado em três classificações: *up* (crescimento), *down* (decréscimo) e *no move* (estacionário), considerando horizontes de previsão e janelas de dados de entrada com 3, 5, 7, 10, 15, 20, 25 e 30 dias. Os resultados obtidos indicam a existência de uma relação entre a extensão da janela de dados de entrada, o horizonte de previsão e a performance preditiva dos modelos avaliados. Previsões mais acuradas são obtidas quando a

---

---

extensão do horizonte de previsão é a igual à da janela de dados de entrada. Uma possível explicação para o resultado observado é que a variação do preço das ações em um horizonte de previsão  $x$  reflete o comportamento observado em um período passado similar, influenciado pelo comprimento  $x$  da janela de entrada que representa este comportamento anterior.

Perez-Mora *et al.* (2017) [203] abordam a aplicação de *Machine Learning* na previsão de preços de 1 a 6 dias no Mercado de Energia Espanhol considerando o uso de variáveis exógenas. Dois modelos foram avaliados, o *Autoregressive Integrated Moving Average with Exogenous Variables* (ARIMAX) e o *Nonlinear Autoregressive Model with Exogenous Inputs* (NARX), e três configurações de entrada foram testadas, uma sem a inclusão de variáveis exógenas, outra considerando a demanda líquida (*i.e.*, demanda total subtraída da geração compulsória, que é dada pela soma da geração solar, eólica e nuclear), e uma terceira considerando a demanda total do sistema. Os resultados obtidos pelos autores indicam que o método ARIMAX consistentemente supera o NARX em performance preditiva. Além disso, os modelos que utilizam a demanda líquida como variável exógena realizam previsões mais acuradas em comparação aos demais modelos.

Zhang *et al.* (2018) [213] introduziram o Xuanwu, um novo sistema destinado à previsão de tendências e velocidade de elevação/redução dos preços de ações na China. O sistema Xuanwu utiliza um algoritmo especial que divide os dados de transação de ações em segmentos de um tamanho definido. Esses segmentos são agrupados em quatro categorias com base em seus padrões de preço de fechamento: crescente, decrescente, estável e indeterminado. Os segmentos são posteriormente subdivididos com base na intensidade de suas tendências, podendo ser classificados como segmentos com taxa de crescimento/decrescimento superior a 30% (UA2 e DA2) ou entre 30% e 10% (UA1 e DA1). Com o objetivo de otimizar suas previsões, o sistema é treinado com base nos segmentos classificados, empregando uma mistura de técnicas como *Random Forest*, *Imbalance Learning* e *Feature Selection*. Quando testado considerando sete anos de dados do *China's Shenzhen Growth Enterprise Market*, o sistema demonstrou resiliência diante das oscilações do mercado, superando diversas abordagens preexistentes em termos de precisão e rentabilidade por operação.

Bustos *et al.* (2020) [214] destacam em sua pesquisa que o mercado de ações, em sua busca constante por previsões mais precisas e estratégias de investimento eficazes, emprega uma ampla variedade de métodos de previsão. O tipo mais proeminente é a Análise Técnica (ou *Technical Analysis*), que se baseia em preços e volumes históricos, e é fundamentada na premissa de todas as novas informações já estão representadas nos preços das ações. Outro método menos

---

---

comum, mas também abrangente, é a Análise Fundamentalista (*Fundamental Analysis*), que utiliza dados macroeconômicos e tem incorporado cada vez mais dados não estruturados, como notícias financeiras. Mineração de texto e análise de redes sociais, com foco em índices de sentimento, são métodos modernos aplicados a essa análise tradicional. Uma revisão recente de 52 estudos publicados entre 2014 e 2018, feita por Bustos *et al.*, identificou que o problema de previsão de mercado é modelado principalmente como um problema de classificação de dados de acordo com a tendência que apresentam (se é de crescimento, decrescimento ou estabilidade dos preços). Neste contexto, os *Technical Indicators* permanecem como a fonte de dados mais popular para previsões, seguidos por análises de redes sociais, que focam principalmente na análise de sentimentos. Algoritmos de *Machine Learning*, especialmente *Ensemble Models*, demonstram alto poder preditivo, muitas vezes superando modelos tradicionais. Notavelmente, modelos que integram múltiplas fontes de informação, especialmente quando combinam indicadores técnicos com dados de blogs e redes sociais, tendem a ter um desempenho superior. Também se observa uma tendência distinta: modelos ajustados para mercados emergentes e de fronteira tendem a ser mais precisos do que os voltados para mercados de países desenvolvidos, talvez em razão da complexidade inerente destes últimos.

Ibrahim *et al.* (2021) [199] avalia a aplicação de *Machine Learning* na previsão de tendências de curtíssimo prazo no preço da criptomoeda Bitcoin (isto é, se o preço vai subir ou descer, considerando janelas temporais de 5 minutos). O Bitcoin ganhou destaque na mídia após relatos de investidores se tornando milionários repentinamente no final de 2017. Flutuações diárias de preços superiores a 10% são frequentes, levando *day-traders* a buscar lucros nesses movimentos de curto prazo. Nesse contexto, *bots* de negociação algorítmica, que empregam algoritmos de *Machine Learning* no processo de tomada de decisão, participam de mais de 60% do volume de negociações. No estudo desenvolvido pelos autores foram avaliados vários modelos, incluindo ARIMA, *Multi-Layer Perceptron (MLP) Neural Networks*, *Random Forest* e a sua variação *Lagged-Auto-Regression*, bem como o modelo *Prophet* (desenvolvido pelo Facebook), que posteriormente tiveram seus resultados comparados àqueles obtidos com duas estratégias de *benchmarking*: *Random Guessing* (a previsão da tendência futura dos preços é definida de forma aleatória) e *Momentum-Based Strategy* (a tendência observada na janela temporal precedente é utilizada como previsão para a próxima janela de preços). Quanto aos preditores, indicadores técnicos, selecionados por sua popularidade entre os *day-traders*, foram usados para capturar várias nuances do mercado, considerando tanto a volatilidade quanto o volume de negociação. Variáveis temporais que detalham a hora, o dia e o mês também foram incorporados. Os resultados

---

---

do estudo revelam que entre os modelos testados, as redes neurais MLP apresentaram o maior nível de acurácia na previsão de tendências de curtíssimo prazo no preço do Bitcoin, atingindo o valor de 54%, além de superar também ambas as estratégias de *benchmark*.

Mchugh *et al.* (2021) [204] explora a aplicação de indicadores técnicos, largamente utilizados no mercado financeiro, no problema de previsão de preços horários no *Irish Integrated Single Electricity Market*. A semelhança entre o mercado financeiro e o mercado de energia da Irlanda, bem como a ampla utilização de indicadores técnicos pelos *traders* no processo de tomada de decisão de compra, venda ou manutenção de posição, fundamentou o desenvolvimento de um conjunto de 8 indicadores direcionados ao mercado energia. Tais indicadores são derivados de dados brutos de preços de energia, podendo ser categorizados como indicadores de tendência, oscilação e momento, que auxiliam no entendimento do comportamento do mercado, bem como na previsão de movimentos de preço. O estudo desenvolvido explora a aplicação dos indicadores junto a três algoritmos de *Machine Learning* para a previsão de preços: *Extreme Gradient Boosting*, *Gradient Boosting* e *Random Forest*. Os resultados obtidos indicam que a aplicação de indicadores técnicos como preditores, em substituição a série temporal bruta de preços, gera previsões de preço mais acuradas, principalmente no caso em que o modelo adotado é o *Random Forest*.

Peng *et al.* (2021) [215] investigam a aplicação de 124 indicadores técnicos na previsão de movimentos de preço usando *Deep ANNs*. A pesquisa concentra-se em identificar indicadores de análise técnica derivados tanto de pesquisas científicas atuais quanto de práticas efetivas de negociação no mercado financeiro, e em seguida testar o desempenho preditivo desses indicadores utilizando redes neurais com diversos níveis de profundidade (3, 5 e 7 *hidden layers*). Além disso, o estudo busca aprimorar a performance desses modelos explorando técnicas de seleção de variáveis de entrada, tais como *Sequential Forward Floating Selection (SFFS)*, *Tournament Screening (TS)* e *Least Absolute Shrinkage and Selection Operator (LASSO)*, para em seguida desenvolver e avaliar estratégias de negociação que levem em conta os custos de transação, refinando assim a aplicação de aprendizado de máquina na análise de mercados financeiros. Os resultados do estudo revelaram que a acurácia preditiva dos modelos desenvolvidos variou entre 50% e, surpreendentemente, 65%, necessitando de mais investigações para o entendimento do valor mais elevado observado. Em termos de rentabilidade, esses modelos, em geral, não superaram a estratégia *Buy-and-Hold* (*i.e.*, estratégia em que um ativo é adquirido e mantido por um longo período, aguardando-se a sua valorização), especialmente em mercados voláteis. O estudo destaca ainda a discrepância entre os indicadores técnicos preferidos no meio acadêmico e aqueles

---

---

utilizados por *traders* no mundo real, observando que alguns indicadores frequentemente ignorados na academia são amplamente usados na prática de negociação. Além disso, foi notado que indicadores criados pela combinação de outros podem reduzir redundâncias e otimizar as previsões. Por fim, a pesquisa aponta para a importância de considerar um limite para os custos de transação, acima do qual o lucro se torna inatingível ou a estratégia *Buy-and-Hold* prevalece, oferecendo uma orientação valiosa para investidores sobre a atratividade de mercados específicos.

Yildirim *et al.* (2021) [198] desenvolveram um modelo híbrido usando redes neurais do tipo *Long Short-Term Memory* para prever movimentos direcionais no mercado FOREX, concentrando-se especificamente no par de moedas Euro/Dólar Americano (EUR/USD). O modelo combina duas abordagens: uma rede LSTM analisa indicadores macroeconômicos (ME\_LSTM), como taxas de juros, inflação e índices de mercado, enquanto a outra foca em indicadores técnicos (TI\_LSTM), incluindo *moving average* (MA), *relative strength index* (RSI) e *Bollinger bands* (BB). As previsões de ambas as redes são sintetizadas através de uma etapa de pós-processamento baseada em regras, que não só harmoniza as previsões, mas também melhora significativamente a confiabilidade do modelo ao minimizar os falsos positivos e negativos. O pós-processamento visa estabelecer uma decisão final combinando as previsões dos modelos ME\_LSTM e TI\_LSTM segundo regras específicas: se um modelo prediz a classe *no action*, esta será a decisão final e nenhum tipo de posição será tomada; se ambos os modelos concordam (seja indicando tendência de crescimento ou decréscimo dos preços), a previsão em comum é adotada. Em caso de discordância, a previsão com maior probabilidade prevalece, ou a da TI\_LSTM se as probabilidades forem iguais. Este método conservador de tomada de decisão minimiza o número de transações, priorizando aquelas mais confiáveis. Os autores demonstram o modelo híbrido proposto alcança uma precisão em torno de 73% quando se avalia o percentual de transações bem-sucedidas fundamentadas em previsões para o dia seguinte, superando os modelos que utilizam exclusivamente indicadores técnicos ou macroeconômicos, o que evidencia a superioridade de uma abordagem integrada em análises complexas do mercado FOREX.

Santos *et al.* (2022) [209] propõem uma nova abordagem que emprega os algoritmos *Random Forest* e *Mixture of Experts* para antecipar as flutuações nos preços da energia no mercado de energia brasileiro, especialmente nas transações realizadas no Balcão Brasileiro de Comercialização de Energia (BBCE). O trabalho visa antecipar as oscilações diárias nos valores da energia para períodos de um, dois e três meses à frente, utilizando algoritmos que agregam diversos dados, como os preços de mercado atuais, indicadores técnicos, além de dados passados e atributos sazonais das séries temporais analisadas. O método *Mixture of Experts* emprega uma

---

estratégia de *dividir e conquistar*, desmembrando um problema intrincado em partes menores e formando modelos especializados para resolver cada parte. A integração dessas soluções é realizada por meio de uma função de *gating*, ajustada para calibrar a saída de cada modelo e gerar um resultado consolidado. Baseado nesse conceito, Santos *et al.* desenvolveram modelos específicos para as classes *up* e *down* (tendência de crescimento e decrescimento do preço da energia), além de um modelo balanceado, todos utilizando o algoritmo *Random Forest* e otimizados para aumentar a precisão em suas respectivas classes. Os resultados demonstram que a abordagem *Mixture of Experts*, ao combinar previsões, oferece desempenho superior em termos de retorno acumulado em comparação com outros métodos, além de permitir a otimização de várias métricas financeiras, sublinhando seu potencial para melhorar os resultados financeiros no setor de comércio de energia.

Castilho Braz *et al.* (2024) [210] propõem uma metodologia para a previsão de movimentos de preços *intraday* e entre dias consecutivos de produtos com maturidade de até 3 meses no mercado de energia brasileiro, explorando várias classes de dados, tais como a) informações históricas do preço da energia, b) vazões naturais e armazenamento de energia, c) chuva realizada e prevista, bem como d) carga realizada e prevista. Utilizando o algoritmo *Random Forest*, modelos individuais foram desenvolvidos para cada classe de dados, sendo estes posteriormente combinados em um ensemble através da técnica *stacking* (empilhamento) e por meio de médias ponderadas. O método *stacking* aplicado neste estudo compreende o treinamento de modelos usando apenas uma das quatro classes de dados por vez, gerando, portanto, 4 modelos especializados. As previsões de tais modelos individuais alimentam um meta-modelo também baseado no algoritmo *Random Forest*, que faz a combinação dessas entradas e gera uma previsão final. Paralelamente, o método de médias ponderadas pelo desempenho ajusta as previsões de cada modelo com base na acurácia histórica de suas previsões, atribuindo maior peso aos modelos que apresentam melhor performance. Os resultados mostram que, apesar de não se destacar em termos de acurácia na previsão dos movimentos de preço, o método de médias ponderadas foi capaz de gerar retornos financeiros superiores àqueles observados com os modelos individuais na maioria dos cenários considerados no estudo.

#### 4.2.2. MOTIVAÇÃO E CONTRIBUIÇÕES

Apesar da vasta gama de publicações voltadas a mercados de ações, criptomoedas e câmbio de moedas, observa-se que a aplicação de algoritmos de *Machine Learning* para a previsão

---

de preços e tendências no mercado livre de energia brasileiro com base nos negócios fechados (e não apenas com o uso das projeções geradas pelos modelos de planejamento da operação do sistema elétrico brasileiro) ainda é limitada. Pouca atenção tem sido dada a esse tema apesar da expansão acelerada pela qual esse ambiente de comercialização vem passando. De fato, preencher tal lacuna é relevante por razões estratégicas e operacionais. Modelos do tipo promovem a tomada de decisões informadas, ajudam na gestão de riscos, otimizam a alocação de recursos, e permitem reações rápidas a mudanças de mercado. Essas ferramentas são cruciais para o planejamento estratégico e conferem vantagem competitiva, permitindo que os agentes antecipem tendências e se posicionem de maneira vantajosa frente à concorrência. Ao utilizar previsões avançadas, os agentes também ganham confiança e credibilidade no mercado, essencial para atrair investimentos e parcerias estratégicas.

Deste modo, o presente estudo objetiva contribuir no âmbito nacional, propondo e explorando a aplicação de *Artificial Neural Networks* no problema de previsão de preços no mercado livre de energia brasileiro. O estudo aborda desde a aplicação de redes neurais clássicas, como a *Multi-layer Perceptron*, até redes neurais mais sofisticadas, com sistemas de gerenciamento do fluxo de informações através de portões, bem como arquiteturas que permitem o fluxo bidirecional dos sinais que permeiam as células de processamento. Além disso, é avaliado o impacto da utilização de preditores baseados em dados relacionados à operação do sistema (carga, energia armazenada e energia natural afluyente) e ao mercado de energia, incluindo o preço calculado pelo operador de mercado para a liquidação das diferenças contratuais. Os experimentos também buscam verificar se as redes neurais testadas são capazes de gerar previsões acuradas de preço e movimento de mercado, bem como um retorno financeiro acumulado positivo, quando as previsões são utilizadas como informação diretiva para a tomada de posição de compra ou venda de energia por parte de um comercializador.

### 4.2.3. ESTRUTURA DO CAPÍTULO

O restante deste capítulo está organizado da seguinte forma: A Seção 4.3 introduz o *framework* desenvolvido para a previsão de preços no ambiente de livre comercialização de energia. Aborda-se a metodologia de pré-processamento dos dados de entrada, a teoria subjacente às arquiteturas de redes neurais implementadas, a abordagem heurística para a seleção dos preditores, e as técnicas de treinamento, validação e teste dos modelos. Também são detalhadas as métricas e o teste de hipóteses para a avaliação da performance preditiva das redes neurais. A

---

---

Seção 4.4 descreve o estudo de caso e as variáveis operativas e de mercado utilizadas no desenvolvimento das redes neurais. Em seguida, a Seção 4.5 discorre sobre os resultados obtidos com as simulações, apresentando uma análise da performance preditiva dos modelos. Esta análise considera os impactos dos preditores e inclui uma avaliação do retorno financeiro que poderia ser alcançado caso as previsões realizadas pelos modelos fossem utilizadas como base para a tomada de posições de curtíssimo prazo no mercado de energia. Finalmente, a Seção 4.6 encerra o capítulo com uma síntese das principais conclusões obtidas no estudo. Além disso, apresentam-se propostas para o aprimoramento dos modelos testados, sugerindo direções futuras para a pesquisa nesta área.

## 4.3. METODOLOGIA

### 4.3.1. FRAMEWORK PARA PREVISÃO DE PREÇOS

O *framework* proposto neste estudo, Figura 28, apresenta as etapas processuais para a previsão (com frequência diária) da curva de preços mensais da Energia Convencional no mercado de energia brasileiro (fontes de dados → variáveis → pré-processamento → redes neurais artificiais → output → performance). Neste esquema, 7 classes de redes neurais artificiais são testadas: a *Multi-Layer Perceptron* e as versões uni- e bidirecionais das redes neurais recorrentes do tipo *Clássica*, *Long Short-Term Memory* e *Gated Recurrent Unit*. Esses modelos são alimentados com dados históricos da operação do sistema elétrico e mercado de energia brasileiro, tais como, carga, energia natural afluyente, armazenamento de energia, preço da energia dos negócios firmados no ambiente de livre comercialização, bem como aquele calculado pelo operador de mercado para a liquidação da energia não coberta por contratos. Nas seções seguintes são apresentados mais detalhes sobre os dados utilizados pelo *framework*, o pré-processamento dessas informações, as redes neurais implementadas, bem como as métricas e teste de hipóteses utilizados para a avaliação dos resultados obtidos.

---

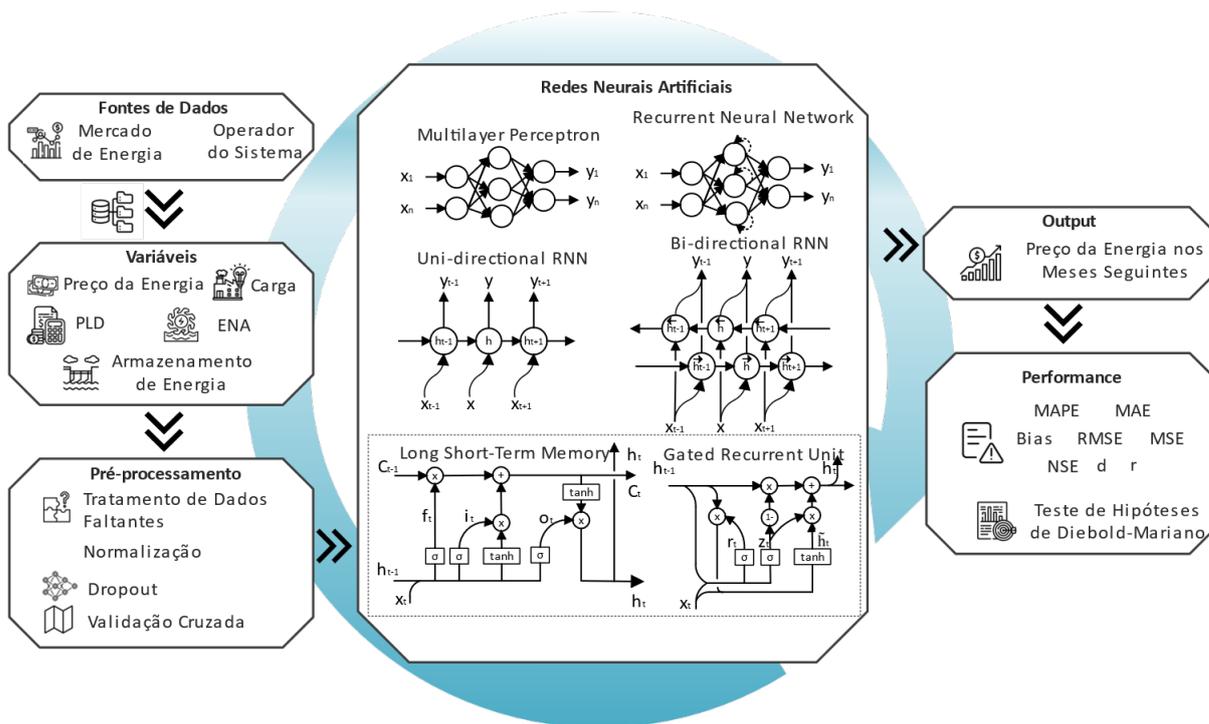


Figura 28 - Visão geral do *framework* proposto para a previsão dos preços da energia no Mercado Livre Brasileiro.

### 4.3.2. PRÉ-PROCESSAMENTO DOS DADOS

A preparação adequada dos dados é um pré-requisito fundamental antes de se proceder à calibração (ou o treinamento) de qualquer modelo de *Machine Learning*. A qualidade e estrutura dos dados impactam diretamente o desempenho do modelo. Processos como correção de valores ausentes, normalização das escalas dos dados e seleção de medidas de tendência central são essenciais para a construção de modelos destinados a aplicações práticas. No *framework* da Figura 28, a etapa de pré-processamento de dados desempenha justamente esse papel. Ela visa adequar os dados brutos para as etapas de treinamento, validação e teste das redes neurais.

Em um contexto prático da presente pesquisa, a mediana dos preços no mercado livre foi adotada como medida de tendência central para os preços diários, visando estabilizar as análises frente às flutuações extremas, conhecidas como *outliers*. Essa estatística foi calculada com base nos vários negócios firmados ao longo de um dia, minimizando a influência de valores atípicos que poderiam distorcer a análise, como ocorreria caso fosse utilizada a média dos preços. O uso da mediana assegura uma representação mais estável da tendência central dos preços, essencial para a precisão dos modelos preditivos que lidam com essa variável. Para o caso das demais variáveis, relacionadas à operação do sistema (carga, energia armazenada e energia natural

---

afluente) e ao mercado de energia (preço calculado pelo operador de mercado para a liquidação das diferenças contratuais), optou-se por utilizar as séries temporais com discretização diária disponibilizadas pelos operadores de mercado e do sistema elétrico brasileiro.

Com relação ao problema dos dados faltantes, comum em grandes conjuntos de dados, adotou-se a técnica de interpolação linear. Este método estima valores ausentes a partir de dados adjacentes, mantendo assim a integridade e continuidade do conjunto de dados, sem introduzir distorções relevantes. Após tratar os dados faltantes, a próxima etapa crucial foi a normalização, na qual os dados foram ajustados para uma escala uniforme de 0 a 1. A normalização é fundamental para que as variáveis de diferentes escalas não impactem de maneira desproporcional o treinamento do modelo, além de facilitar a otimização dos algoritmos de aprendizado, resultando em uma convergência mais rápida e estável. Posteriormente, os dados foram segmentados em três conjuntos distintos: treinamento, validação e teste. O conjunto de treinamento é utilizado para ajustar os parâmetros do modelo, enquanto o conjunto de validação é empregado para assegurar a robustez do modelo contra o *overfitting* (i.e., o modelo se ajusta excessivamente aos dados de treinamento, comprometendo sua capacidade de generalização para novos conjuntos de dados). O conjunto de teste, por sua vez, serve para avaliar a capacidade do modelo de generalizar para novos dados, simulando seu desempenho em ambientes de aplicação real.

Ainda na linha de mitigação do *overfitting* das redes neurais, foi implementada a técnica *dropout* no processo de treinamento das redes neurais. *Dropout* é uma técnica de regularização que desativa aleatoriamente uma fração dos neurônios em cada iteração de treinamento a fim de reduzir a dependência do modelo em qualquer característica isolada dos dados de entrada, promovendo o aprendizado de padrões mais generalizados. No presente estudo, uma taxa de dropout de 20% foi aplicada nas camadas ocultas das redes neurais consideradas, o que significa que, aleatoriamente, 20% dos neurônios são "desligados" em cada iteração do treinamento.

### 4.3.3. MULTI-LAYER PERCEPTRON NEURAL NETWORKS

As redes neurais artificiais são modelos matemáticos que operam de forma similar às redes neurais biológicas [78], [79]. Elas obtêm conhecimento através de um processo sistemático de treinamento, no qual identificam e assimilam os padrões e conexões presentes em um determinado conjunto de dados [80]. Após a etapa de aprendizado, as redes se tornam ferramentas eficazes para a classificação de informações ou para a previsão de séries temporais, a depender do objetivo específico para o qual foram treinadas. Em especial, as redes neurais *Multi-Layer*

---

*Perceptron* (MLP) são redes com camadas sequenciais de neurônios artificiais que compartilham conexões entre si e processam informações em um único sentido, isto é, a partir da camada de entrada, passando pelas camadas intermediárias, até chegar à camada de saída [80], [81]. Sua aplicação abrange diversas vertentes, incluindo, por exemplo, a previsão de carga em sistemas elétricos [216], [217], previsão de vazões afluentes a hidrelétricas e reservatórios [82], [218], previsão de geração eólica [219], [220], bem como solar [221]. As redes MLP desenvolvidas neste estudo recebem os dados das séries temporais dos preditores e os direcionam para a primeira camada oculta, onde são realizadas combinações lineares  $\sum_{i=1}^N w_i x_{i,t}$  (ou  $w \circ x_t$ , em termos de produto interno de vetores) em cada neurônio artificial, aplicando-se pesos  $w_i$  às entradas  $x_i$  ( $i = 1, \dots, N$ ). Ao resultado da soma de produtos é acrescido um viés  $b$ , que é posteriormente transformado via função de ativação  $f(\cdot)$ , resultando em um sinal  $h_t$  expresso em (21). Esse processo é repetidamente executado nas camadas ocultas subsequentes, até que a camada de saída reúna os resultados, realizando uma soma ponderada para então gerar a previsão.

$$h_t = f(w \circ x_t + b) \quad (21)$$

#### 4.3.4. RECURRENT NEURAL NETWORKS

As *Recurrent Neural Networks* (RNNs) são uma classe de redes neurais especializadas no processamento de dados sequenciais, como séries temporais, linguagem natural, ou qualquer tipo de dados onde a ordenação das informações é importante [222], [223]. O aspecto distintivo das RNNs, em comparação às redes do tipo MLP, é a sua capacidade de manter um estado ou memória, o que lhes permite capturar características temporais ou sequenciais dentro de um conjunto de dados. Na sua formulação clássica, os neurônios de uma RNN possuem um loop de realimentação em que o estado oculto relacionado ao tempo  $t - 1$  anterior a  $t$ ,  $h_{t-1}$ , é ponderado e reconsiderado, resultando no sinal  $h_t$  expresso em (22). Note que a expressão é similar, mas não idêntica, à das redes MLP, se diferenciando pela concatenação da entrada  $x_t$  ao estado oculto anterior  $h_{t-1}$ .

$$h_t = f(w \circ [h_{t-1}, x_t] + b) \quad (22)$$

Dentro do contexto das RNNs clássicas, dois obstáculos do processo de treinamento são identificados quando se tenta construir modelos com muitos *layers* ocultos de neurônios: o

desvanecimento e a explosão dos gradientes (em inglês, *vanishing and exploding gradient problems*) [224], [225]. O problema dos gradientes que desvanecem ocorre em RNNs quando os valores dos gradientes diminuem exponencialmente durante o treinamento no passo de retropropagação de erros (o algoritmo propaga o erro de saída de volta pela rede, camada por camada, ajustando os pesos dos neurônios de forma a reduzir as diferenças entre as saídas reais e as estimadas pela rede), tornando as atualizações de pesos nas camadas iniciais quase nulas. Isso impede a rede de aprender relações entre eventos distantes na sequência de dados, dificultando a captura de dependências de longo prazo. Em contrapartida, o problema dos gradientes que explodem é oposto ao do desvanecimento e ocorre quando os valores dos gradientes aumentam exponencialmente durante a retropropagação, levando a grandes atualizações de peso. Esse aumento pode causar oscilações nos parâmetros da rede, resultando em instabilidade no treinamento e, frequentemente, em um modelo que não converge ou aprende padrões inadequados.

Uma variante aperfeiçoada das redes recorrentes é a rede *Long Short-Term Memory* (LSTM) proposta por Hochreiter e Schmidhuber em 1997 [222]. Seu diferencial reside na sua capacidade de processar dados por meio de portões e armazenar informações passadas numa estrutura conhecida como “célula de memória”. O estado da célula  $C_t$  é um componente crucial na arquitetura LSTM, atuando como a “memória” da rede que carrega informações por muitos passos de tempo. Essencialmente, permite que LSTMs lembrem ou esqueçam informações ao longo de longos períodos, tornando-as eficazes para tarefas envolvendo dados sequenciais, como, por exemplo, previsão de séries temporais [216], [226], [227] e processamento de linguagem natural [228], [229].

Uma unidade ou célula LSTM é composta por vários “portões”: um *Input Gate*, um *Output Gate* e um *Forget Gate*. Estruturas que controlam toda a informação que entra e sai da unidade de processamento, bem como a atualização do estado da célula.

- O *Forget Gate* decide quais informações devem ser descartadas do estado da célula. O portão recebe o estado oculto anterior e a entrada atual,  $[h_{t-1}, x_t]$ , processa-os por meio de uma função sigmoideal,  $\sigma$ , para então produzir valores entre 0 e 1, conforme mostra a expressão (23), onde  $w_f$  e  $b_f$  são, respectivamente, os pesos e o viés aplicado. Um valor próximo a 0 significa que a informação deve ser descartada, enquanto um valor próximo a 1 significa que ela deve ser armazenada.

$$f_t = \sigma(w_f \circ [h_{t-1}, x_t] + b_f) \quad (23)$$

- O *Input Gate* determina quais novas informações devem ser adicionadas ao estado da célula. Este portão tem duas partes: uma camada sigmoideal que decide quais valores atualizar,  $i$ , e uma camada  $\tanh$  que cria um vetor de novos valores candidatos,  $\tilde{C}_t$ , a serem adicionados ao estado, conforme mostram as equações (24) e (25), em que  $w_i$ ,  $w_c$ ,  $b_i$ , e  $b_c$  são pesos e vieses.

$$i_t = \sigma(w_i \circ [h_{t-1}, x_t] + b_i) \quad (24)$$

$$\tilde{C}_t = \tanh(w_c \circ [h_{t-1}, x_t] + b_c) \quad (25)$$

O antigo estado da célula  $C_{t-1}$  é atualizado para o novo estado da célula  $C_t$  em (26). O estado anterior é multiplicado pela saída do *Forget Gate*,  $f_t \odot C_{t-1}$ , eliminando da memória os elementos que se decidiu esquecer, sendo que o operador  $\odot$  denota o produto de Hadamard. A partir desse passo, adiciona-se o produto da saída do *Input Gate* e o estado candidato,  $i_t \odot \tilde{C}_t$ , para atualizar o estado da célula com novas informações.

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (26)$$

- O *Output Gate* decide qual deve ser o próximo estado oculto,  $h_t$ . Nessa etapa, o estado da célula,  $C_t$ , passa por uma função tangente hiperbólica para então ser multiplicado pela saída do *Output Gate*,  $o_t$ , conforme mostram as equações (27) e (28), onde  $w_o$  e  $b_o$  são, respectivamente, o peso e o viés associado ao portão.

$$o_t = \sigma(w_o \circ [h_{t-1}, x_t] + b_o) \quad (27)$$

$$h_t = o_t \odot \tanh(C_t) \quad (28)$$

Além das redes LSTM, existe uma segunda variação das RNNs, denominada *Gated Recurrent Unit (GRU) Neural Network*. A arquitetura GRU foi proposta por Cho *et al.* [230] em 2014 para realizar tarefas semelhantes às LSTMs, como identificar dependências de longo prazo em sequências de dados, utilizando-as em problemas de previsão [216], [231], [232], mas com uma estrutura menos complexa. A GRU simplifica o modelo da LSTM ao combinar o *Forget Gate*

e a *Input Gate* em uma única porta de atualização, denominada *Update Gate*. Ela também mescla o estado da célula e o estado oculto, reduzindo o número de operações necessárias.

Com relação aos portões, o fluxo de informação é gerenciado da seguinte forma:

- O *Update Gate* determina quanto do estado oculto anterior,  $h_{t-1}$ , deve ser mantido. De forma similar ao que ocorre para as redes do tipo LSTM, esse portão,  $z_t$ , decide quanto da informação do estado oculto anterior precisa ser passado para o futuro, ajudando o modelo a aprender dependências de longo prazo, conforme mostra (29), em que  $w_z$  e  $b_z$  são, respectivamente, o peso e o viés associado.

$$z_t = \sigma(w_z \circ [x_t, h_{t-1}] + b_z) \quad (29)$$

- O *Reset Gate*, expresso em (30), decide quanto do estado oculto anterior será esquecido. Isso permite que a GRU descarte informações que não são mais necessárias para a previsão atual, facilitando o modelo a aprender dependências de curto prazo.

$$r_t = \sigma(w_r \circ [x_t, h_{t-1}] + b_r) \quad (30)$$

As redes GRU utilizam  $z_t$  e  $r_t$  na determinação do estado oculto atual,  $h_t$ , que é calculado com base em uma combinação do estado oculto anterior,  $h_{t-1}$ , e um candidato a novo estado oculto,  $\tilde{h}_t$ , como mostram as equações (31) e (32), em que  $w_h$  e  $b_h$  são, respectivamente, o peso e o *bias* associado.

$$\tilde{h}_t = \tanh(w_h \circ [x_t, r_t \odot h_{t-1}] + b_h) \quad (31)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (32)$$

#### 4.3.5. BIDIRECTIONAL RECURRENT NEURAL NETWORKS

As *Bidirectional Recurrent Neural Networks* (BRNNs) [233] são uma evolução das RNNs tradicionais, projetadas para melhorar o desempenho em tarefas onde tanto o contexto anterior quanto posterior são relevantes para a compreensão de uma entrada específica. Em uma RNN convencional, a informação é processada sequencialmente, o que limita a capacidade da rede

de utilizar informações futuras durante a análise de um dado momento da sequência de dados. As BRNNs abordam essa limitação processando os dados nos dois sentidos do eixo temporal: da esquerda para a direita (*forward*) e da direita para a esquerda (*backward*). Isso é realizado por meio de duas camadas ocultas separadas, cada uma processando a sequência de entrada em uma direção,  $\vec{t} = 1, \dots, T$  ou  $\tilde{t} = T, \dots, 1$ .

Seguindo as diretrizes apresentadas, o estado oculto do tipo *forward*,  $\vec{h}_t$ , é dado por (33), enquanto o do tipo *backward*,  $\tilde{h}_t$ , é expresso por (34). Os estados ocultos são então combinados para a composição da saída  $y_t$ , como mostra a equação (35), onde  $w_{x,\vec{h}}$ ,  $w_{x,\tilde{h}}$ ,  $w_{y,\vec{h}}$  e  $w_{y,\tilde{h}}$  são pesos e  $b_{\vec{h}}$ ,  $b_{\tilde{h}}$  e  $b_y$  vieses.

$$\vec{h}_t = \tanh(w_{x,\vec{h}} \circ [x_t, \vec{h}_{t-1}] + b_{\vec{h}}) \quad (33)$$

$$\tilde{h}_t = \tanh(w_{x,\tilde{h}} \circ [x_t, \tilde{h}_{t+1}] + b_{\tilde{h}}) \quad (34)$$

$$y_t = w_{y,\vec{h}} \vec{h}_t + w_{y,\tilde{h}} \tilde{h}_t + b_y \quad (35)$$

#### 4.3.6. SELEÇÃO DE PREDITORES

No presente estudo foram consideradas  $n$  classes de possíveis preditores que serão detalhadas mais profundamente na seção que apresenta o estudo de caso (Seção 4.4). No contexto de *Machine Learning*, um preditor refere-se a uma variável utilizada para fazer previsões ou estimativas sobre alguma outra variável de interesse. Em outras palavras, preditores são as características ou atributos de entrada que alimentam o algoritmo de *Machine Learning*, permitindo que ele analise padrões nos dados e faça previsões ou classificações com base nessas informações. No estudo apresentado aqui, os preditores são formados com base nas séries temporais históricas de variáveis relevantes que caracterizam a evolução temporal do Sistema Interligado Nacional (carga, energia armazenada e energia fluente), bem como do Mercado de Energia Brasileiro (o preço calculado pelo operador de mercado e o preço negociado pelos agentes no ambiente de livre comercialização).

Para o caso de cada preditor, foram testadas configurações em que as redes neurais são alimentadas com os últimos 7 e 14 registros da série temporal associada (*i.e.*, *lags* 1-7 e 1-14), bem como configurações em que o preditor não é considerado pelo modelo. O intuito da avaliação de uma gama variada de configurações é verificar se de fato a inclusão de um determinado preditor,

ou ainda, se determinada combinação de preditores considerando *lags* variadas, contribui para a elevação da performance preditiva das redes neurais. A exemplo disso, considere 2 candidatos a preditores, A e B, e duas opções de *lags*, 1-7 e 1-14, as combinações possíveis a serem testadas nesse caso são  $(A_{lag\_14}, B_{lag\_14})$ ,  $(A_{lag\_7}, B_{lag\_7})$ ,  $(A_{lag\_7}, NA)$ ,  $(NA, B_{lag\_7})$ ,  $(A_{lag\_14}, NA)$  e  $(NA, B_{lag\_14})$ , em que NA indica a não inclusão de um preditor específico. Nesse esquema, quando mais de um preditor é considerado em uma mesma configuração, todos eles entram com o mesmo número de *lags* no modelo.

#### 4.3.7. CROSS-VALIDATION

As redes neurais apresentadas nesse estudo foram desenvolvidas utilizando a técnica *K-Fold Cross-Validation* [234] na etapa de treinamento e validação. Essa metodologia divide o conjunto de dados total em  $k$  partes de tamanhos iguais, de forma que, sequencialmente, todas elas são exploradas tanto para treinamento (*i.e.*, otimização dos parâmetros da rede neural) quanto para validação. O processo consiste em realizar  $k$  iterações de treinamento e validação, onde, a cada iteração, um fold diferente é reservado para a validação do modelo, enquanto os outros  $k-1$  folds remanescentes são utilizados no processo de treinamento. Nesse esquema, o conjunto de validação é utilizado para determinar o momento certo para a interrupção do processo de treinamento, evitando assim o *overfitting* do modelo e garantindo um modelo com capacidade de generalização. Com a determinação dos parâmetros ótimos da rede neural através da técnica *K-Fold Cross-Validation*, o modelo é testado a partir de sua aplicação em um conjunto de dados totalmente novo. No estudo conduzido aqui, foram considerados 5 folds definidos com base nos dados de 01/02/2018 até 28/02/2021. O teste, por sua vez, foi realizado considerando o período que vai de 01/03/2021 a 24/02/2022.

#### 4.3.8. MÉTRICAS E TESTE DE HIPÓTESES PARA A AVALIAÇÃO DE PERFORMANCE

As métricas consideradas na avaliação das previsões realizadas pelas redes neurais tem suas definições apresentadas na Tabela 10. No equacionamento apresentado,  $\hat{y}_n$  e  $y_n$  denotam, respectivamente, o preço previsto e o preço oficial para o período  $n$ , considerando  $n = 1, \dots, N$ , enquanto  $\bar{\hat{y}}$  e  $\bar{y}$  representam, respectivamente, as médias das séries temporais associadas.

Tabela 10 - Métricas de avaliação de desempenho.

Métricas	Descrição
Mean Absolute Error (MAE)	<p>O MAE é uma métrica utilizada para medir a precisão de previsões feitas por modelos matemáticos [189]. Ele calcula a média das diferenças absolutas entre os valores previstos e os valores observados (<math>0 \leq MAE \leq \infty</math>), tratando as diferenças calculadas ponto-a-ponto <math> \hat{y}_n - y_n </math> na mesma escala, sem dar ênfase desproporcional a grandes desvios.</p> $MAE = \frac{1}{N} \sum_{n=1}^N  \hat{y}_n - y_n  \quad (36)$
Mean Absolute Percentage Error (MAPE)	<p>O MAPE é a métrica que mede a média dos erros absolutos das previsões em relação aos valores reais, expressos em porcentagem [189]. Segundo Chen <i>et al.</i> [89], o MAPE (<math>0 \leq MAPE \leq \infty</math>) pode ser classificado nos seguintes intervalos pré-definidos:</p> <ul style="list-style-type: none"> <li>▪ <b>Previsão altamente precisa:</b> MAPE de 0% a 10% → as previsões têm um erro mínimo;</li> <li>▪ <b>Previsão boa:</b> MAPE de 10% a 20% → as previsões estão dentro de uma faixa considerada confiável e precisa;</li> <li>▪ <b>Previsão razoável:</b> MAPE de 20% a 50% → as previsões são moderadamente precisas;</li> <li>▪ <b>Previsão imprecisa:</b> MAPE superior a 50% → as previsões têm erros substanciais.</li> </ul> $MAPE = \frac{1}{N} \sum_{n=1}^N \left  \frac{\hat{y}_n - y_n}{y_n} \right  \quad (37)$
Bias	<p>O <i>bias</i>, também conhecido como erro médio, serve para avaliar o quanto as estimativas se desviam dos valores reais em um conjunto de dados [189]. Ao invés de focar no valor absoluto das diferenças, o <i>bias</i> ajuda a entender se as previsões tendem a ser consistentemente maiores ou menores que os valores observados (<math>-\infty \leq bias \leq \infty</math>). Idealmente, o viés deve estar próximo de zero, indicando a possível ausência de tendências sistemáticas de subestimação ou sobrestimação nas previsões. Frise-se aqui que, nesse caso ideal, o <i>bias</i> deve ser analisado junto a outras métricas de erro (<i>e.g.</i>, MAE e MAPE), visto que existe a possibilidade de cancelamento entre termos <math>(\hat{y}_n - y_n)</math> com sinais opostos, levando à falsa impressão de que os desvios entre as duas séries temporais comparadas são, em geral, de baixo valor.</p> $bias = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n) \quad (38)$
Root Mean Squared Error (RMSE)	<p>O RMSE quantifica a magnitude dos erros gerados pelo modelo, independentemente de serem positivos ou negativos, fornecendo uma medida da variação dessas diferenças [189]. O RMSE (<math>0 \leq RMSE \leq \infty</math>) é particularmente útil porque penaliza mais erros maiores do que erros menores, dado o uso do quadrado das diferenças. Isso significa que modelos com previsões que estão consistentemente longe dos valores reais terão um RMSE relativamente alto, indicando um desempenho pior.</p> $RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2} \quad (39)$

Mean  
Squared  
Error  
(MSE)

O MSE é uma métrica usada para medir a qualidade de um modelo preditivo, quantificando a variabilidade dos erros das previsões [189]. Uma das vantagens do MSE ( $0 \leq MSE \leq \infty$ ) é que, ao elevar os erros ao quadrado, dá-se mais peso aos erros maiores, o que pode ser particularmente útil quando grandes desvios são indesejáveis.

$$MSE = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2 \quad (40)$$

Nash-  
Sutcliffe  
Efficiency  
Coefficient  
(NSE)

O NSE é uma métrica que avalia a similaridade entre previsões e dados observados [90]. Segundo Moriase *et al.* [91], o NSE ( $0 \leq NSE \leq 1$ ) pode ser classificado em quatro faixas de valores, cada uma indicando um nível diferente de desempenho das previsões:

- **Desempenho muito bom:** NSE de 0,75 a 1,00;
- **Desempenho bom:** NSE de 0,75 a 0,65;
- **Desempenho satisfatório:** NSE de 0,50 a 0,65;
- **Desempenho insatisfatório:** NSE de 0,00 a 0,50.

Vale ressaltar que valores negativos de NSE sugerem que a média dos dados observados é uma previsão melhor do que a realizada pelo modelo sob análise.

$$NSE = 1 - \frac{\sum_{n=1}^N (\hat{y}_n - y_n)^2}{\sum_{n=1}^N (y_n - \bar{y})^2} \quad (41)$$

Índice de  
Willmott  
(d)

O  $d$  é uma métrica usada para quantificar a precisão das previsões de um modelo em comparação com valores observados. Segundo Willmott *et al.* [235], valores de  $d$  ( $0 \leq d \leq 1$ ) próximos de 0 indicam um desempenho ruim do modelo, refletindo uma grande discordância entre as previsões e os dados observados, enquanto valores próximos a 1 demonstram elevada concordância, indicando um excelente ajuste do modelo à realidade observada.

$$d = 1 - \frac{\sum_{n=1}^N (\hat{y}_n - y_n)^2}{\sum_{n=1}^N (|\hat{y}_n - \bar{y}| + |y_n - \bar{y}|)^2} \quad (42)$$

Coefficiente  
de  
Correlação  
de Pearson  
(r)

O  $r$  é uma estatística que quantifica o quão forte é a relação linear existente entre dois conjuntos de dados [189]. Segundo Hinkle *et al.* [236],  $r$  ( $-1 \leq r \leq 1$ ) pode ser classificado em 5 faixas, cada uma indicando um nível distinto de intensidade da relação linear entre os conjuntos de dados:

- **Correlação positiva (negativa) muito alta:** de 0,90 a 1,00 (-0,90 a -1,00) → indica uma relação linear muito forte entre as variáveis, movendo-se juntas na mesma direção (positiva) ou em direções opostas (negativa);
- **Correlação positiva (negativa) alta:** de 0,70 a 0,90 (-0,70 a -0,90) → representa uma relação linear forte, mas não tão perfeita quanto a correlação muito alta;
- **Correlação positiva (negativa) moderada:** de 0,50 a 0,70 (-0,50 a -0,70) → sugere uma relação linear apreciável entre as variáveis, embora com variações que não são totalmente explicadas pela linearidade;
- **Correlação positiva (negativa) fraca:** de 0,30 a 0,50 (-0,30 a -0,50) → indica uma relação linear tênue, com muitos dos pontos de dados não seguindo bem a linha de melhor ajuste;
- **Correlação positiva (negativa) muito fraca:** de 0,00 a 0,30 (0,00 a -0,30) → representa uma relação linear quase inexistente ou muito tênue entre as variáveis.

$$r = \frac{\sum_{n=1}^N [(y_n - \bar{y})(\hat{y}_n - \bar{\hat{y}})]^2}{\sqrt{\sum_{n=1}^N (y_n - \bar{y})^2 \sum_{n=1}^N (\hat{y}_n - \bar{\hat{y}})^2}} \quad (43)$$

Em seguida, a Tabela 11 apresenta em detalhes o Teste de Hipóteses de Diebold-Mariano, que é um método estatístico desenvolvido para comparar a acurácia de duas séries temporais de previsões. Proposto em [93], este teste é extensivamente utilizado para determinar se as diferenças de desempenho observadas entre previsões provenientes de dois modelos distintos são estatisticamente significativas.

Tabela 11 - Teste de hipóteses para comparação par a par das previsões.

Teste	Descrição
DMT	<p>O Teste de Hipóteses de Diebold-Mariano [93] é um método estatístico amplamente utilizado para a análise da acurácia de duas séries temporais de previsões, aqui denominadas de séries A e B. Neste método, a função diferencial de perdas <math>d</math> quantifica para cada <math>n</math> a diferença pontual <math>d_n = loss(e_{A,n}) - loss(e_{B,n})</math> entre os erros computados para A e B, onde <math>loss(e_{A,n})</math> e <math>loss(e_{B,n})</math> representam o erro absoluto (ou o erro quadrático). Nesse teste, a hipótese nula <math>H_0</math> afirma que quando a esperança matemática de <math>d</math>, <math>E(d)</math>, é igual a zero, as séries temporais avaliadas possuem o mesmo nível de acurácia. Por outro lado, a hipótese alternativa sugere que, se a esperança matemática de <math>d</math> for diferente de zero, então o nível de acurácia das séries não é igual (<i>i.e.</i>, umas das séries é mais acurada que a outra). O resultado do teste é obtido através da avaliação do <i>p-value</i>, estatística calculada com base na distribuição de probabilidades acumulada de DMT. Se seu valor for superior a um determinado nível de significância <math>\alpha</math> (<i>e.g.</i>, <math>\alpha = 0,05</math>), pode-se afirmar que existem evidências suficientes para aceitar a hipótese nula, caso contrário ela é rejeitada.</p> <p>No equacionamento apresentado em (44), os termos são os seguintes:</p> <ul style="list-style-type: none"> <li>▪ <math>CDF</math> é a função densidade de probabilidade acumulada;</li> <li>▪ <math>h</math> é o horizonte de previsão;</li> <li>▪ <math>\gamma_k</math> é a autocovariância de <math>d</math> considerando a lag <math>k</math>;</li> <li>▪ <math>N</math> é a quantidade de dados de cada série temporal avaliada; e</li> <li>▪ <math>\bar{d}</math> é a média dos valores da função diferencial de perda.</li> </ul> $H_0: E(d) = 0$ $H_a: E(d) \neq 0$ $DMT_{calc} = \frac{\bar{d}}{\sqrt{\frac{\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k}{N}}} \quad (44)$ $p\text{-value} = 2 \times [1 - CDF(DMT_{calc})]$

A autora desta tese de doutorado foi responsável por toda a implementação das redes neurais artificiais, pela condução das simulações de *backtest*, e pela análise detalhada dos resultados obtidos ao longo do estudo. Todos esses processos foram desenvolvidos utilizando a linguagem de programação R.

---

## 4.4. ESTUDO DE CASO

### 4.4.1. MERCADO LIVRE DE ENERGIA BRASILEIRO

No Brasil, a energia elétrica produzida pelas usinas pode ser comercializada em dois ambientes de contratação: o Ambiente de Contratação Regulada e (ACR) o Ambiente de Contratação Livre (ACL). Cada um destes mercados apresenta características próprias, especialmente no que tange à autonomia concedida aos agentes envolvidos para a definição das cláusulas contratuais. O ACR, por exemplo, caracteriza-se por um sistema de comercialização baseado em leilões de compra e venda de energia, em que concessionárias, permissionárias e autorizadas de serviço público de distribuição adquirem energia elétrica de agentes geradores, comercializadores ou importadores para o atendimento de seu mercado cativo de consumidores. Ele é um ambiente que possui regulação específica para aspectos como preço da energia elétrica e período de suprimento, além de considerar Contratos de Comercialização no Ambiente Regulado (CCEARs) que estabelecem cláusulas e condições fixas não passíveis de alteração. Em contrapartida, o ACL tem como característica a livre negociação entre geradores, comercializadores, importadores e consumidores livres ou especiais. Neste ambiente, aspectos contratuais como montante de energia comercializada, preço, período de suprimento, tipo de energia e modulação são livremente definidos entre as partes no processo de negociação e firmados via Contratos de Comercialização de Energia no Ambiente Livre (CCEALs), instrumentos que permitem uma flexibilidade maior em comparação com o ACR [237], [238].

### 4.4.2. PREÇO DA ENERGIA CONVENCIONAL

No ACL, grande parte das negociações entre agentes vendedores e compradores de energia é feita através de plataformas digitais. Nesse tipo de ambiente os agentes podem acessar ofertas em tempo real, fechar negócios bilaterais em tela, participar de leilões digitais de compra ou venda de energia, ou até formalizar negócios que foram iniciados via telefone. A energia pode ser negociada seguindo formatos estabelecidos, com prazos de suprimento uniformizados e classificação por submercado (*i.e.*, Sudeste/Centro-Oeste, Sul, Nordeste e Norte) e tipo de energia.

Dentro deste contexto de negociação digital, três principais tipos de energia são comercializados: Energia Convencional (EC), gerada por fontes tradicionais como termelétricas e grandes hidrelétricas; Energia Incentivada (EI), proveniente de fontes renováveis como eólica, solar, biomassa e pequenas centrais hidrelétricas, beneficiadas por incentivos governamentais; e

---

---

Energia de Cogeração Qualificada (ECQ), que é produzida através de um processo eficiente que combina a geração de energia elétrica e calor útil, podendo utilizar tanto fontes renováveis quanto combustíveis fósseis. Quanto aos preços estabelecidos para os ativos, eles podem ser fixos ou indexados ao Preço de Liquidação das Diferenças (PLD). No modelo indexado ao PLD, um valor fixo de ágio ou deságio é aplicado sobre o PLD vigente, o que implica em possíveis alterações mensais do valor do ativo. Já na modalidade preço fixo, o valor atribuído a cada MWh comercializado é constante ao longo de todo o horizonte de suprimento.

Dentre os tipos de energia comercializada, a EC do Submercado Sudeste valorada a um preço fixo é o ativo de maior popularidade comercial e, portanto, o mais importante para os agentes que atuam no ACL. Na Figura 29 a. são apresentados os valores máximo e mínimo, bem como a média e a mediana dos preços da Energia Convencional (Preço EC) para blocos de energia a serem entregues no mês seguinte a data de negociação. Em complemento, a Figura 29 b. mostra a amplitude e o desvio padrão diário do mesmo conjunto de dados entre os anos de 2018 e 2022. Essa variação nos preços ao longo do tempo cria um ambiente dinâmico, onde agentes vendedores e compradores têm a oportunidade de estabelecer estratégias de atuação, negociar contratos e fechar negócios. Para os agentes que tomam decisões informadas, a variabilidade dos preços é uma fonte potencial de ganhos, pois permite que os participantes do mercado executem estratégias com expectativa de maiores retornos financeiros por meio da exploração de tendências, oscilações e diferenças de preço.

#### 4.4.3. PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS

O PLD é o preço da energia no Mercado de Curto Prazo (MCP). Ele é definido com base no Custo Marginal da Operação (CMO) limitado a valores de teto e piso, calculado pelo modelo matemático DESSEM que simula a operação do Sistema Interligado Nacional (SIN) para o dia seguinte, considerando um regime de precificação horária e zonal, em que cada área do sistema elétrico corresponde a um submercado (Sudeste/Centro-Oeste, Sul, Nordeste e Norte). No MCP, o PLD serve como sinal econômico que indica o custo marginal para atender à demanda adicional de eletricidade do SIN, sendo utilizado na liquidação financeira das diferenças entre a energia contratada e a energia efetivamente consumida ou gerada pelos agentes de mercado. Além de sua função básica no processo de liquidação financeira das diferenças, o PLD também serve de referência para os agentes que estabelecem estratégias de atuação no ACL, estratégias estas muito influenciadas pela expectativa futura do preço da energia no MCP. A Figura 29 c. apresenta a

---

evolução temporal do PLD no Submercado Sudeste/Centro-Oeste, onde se observa uma notável semelhança com a mediana do Preço EC na Figura 29 a.

#### 4.4.4. CARGA

No Brasil, a energia elétrica demandada pelos consumidores é monitorada e utilizada como dado de entrada no modelo matemático responsável por calcular o PLD. À medida que o

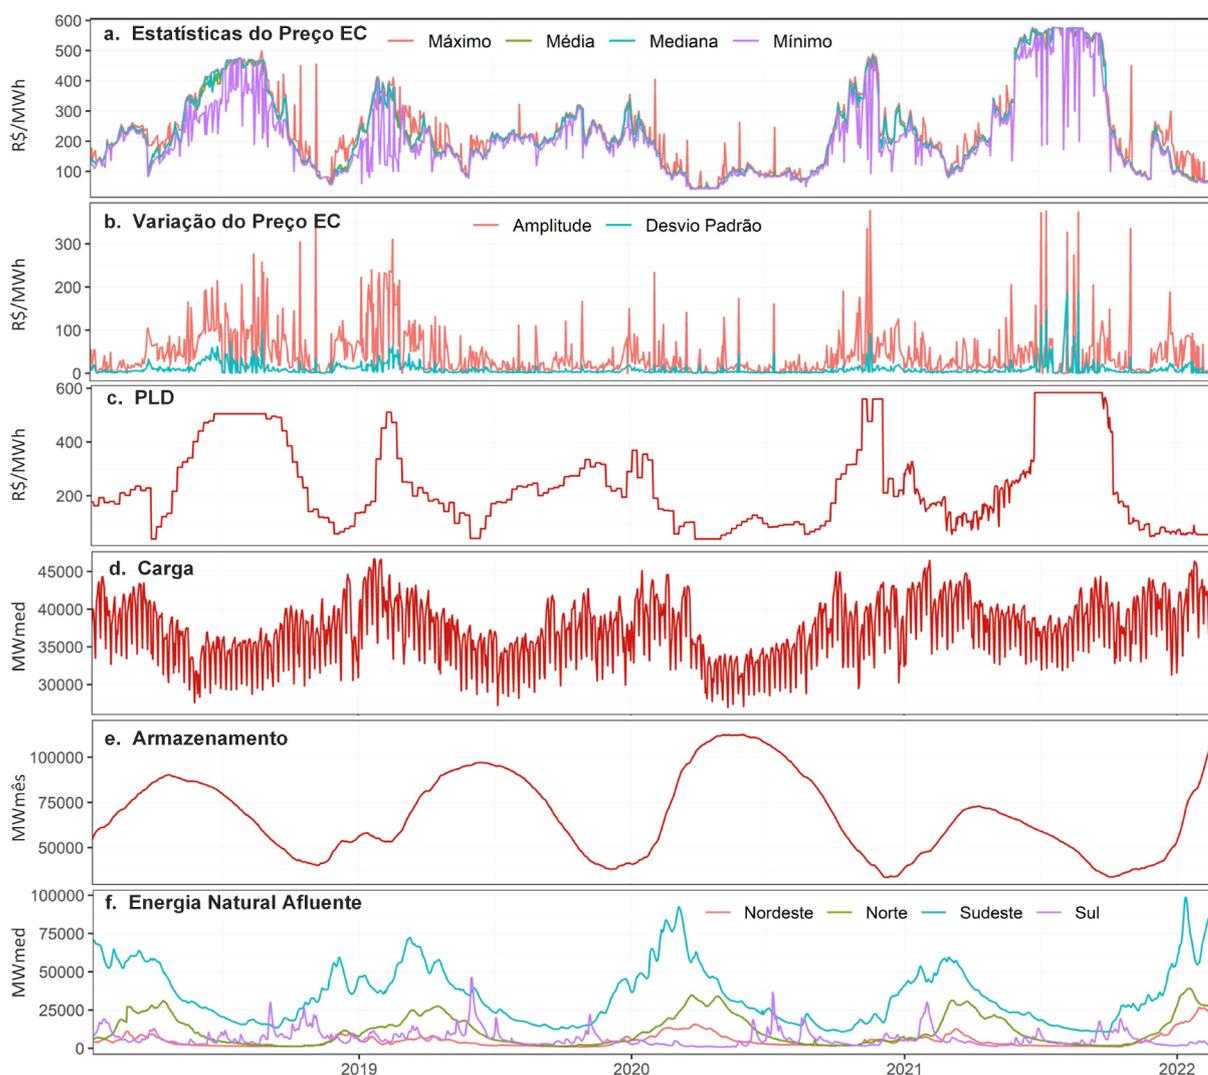


Figura 29 - As séries temporais consideradas no framework de previsão de preços incluem: (a.) os valores máximo e mínimo, bem como a média e a mediana do preço da energia convencional a ser gerada no mês seguinte (apenas mês 1 do horizonte da Curva Forward de preços); (b.) a amplitude e o desvio padrão dos preços negociados para a energia convencional; (c.) o Preço de Liquidação das Diferenças do Submercado Sudeste; (d.) a carga total do Submercado Sudeste; (e.) a energia armazenada no Submercado Sudeste/Centro-Oeste; e (f.) a energia natural afluyente aos submercados Sudeste/Centro-Oeste, Sul, Nordeste e Norte.

---

consumo energético diário varia, pode-se tornar necessário ativar unidades geradoras de energia mais custosas, resultando em um aumento do CMO, que é fundamental na formulação do PLD, conseqüentemente influenciando os níveis do Preço EC. A Figura 29 d. mostra a série temporal das médias diárias da carga do submercado Sudeste/Centro-Oeste, abrangendo um período que vai de 2018 até 2022.

#### 4.4.5. ENERGIA ARMAZENADA

A energia armazenada (EArm) nos submercados do SIN é um recurso estratégico para garantia de suprimento de energia durante os meses em que o nível de precipitação e vazões é baixo (período seco), bem como é fundamental para o equilíbrio entre a oferta e a demanda de energia variável dos consumidores. Essa capacidade de armazenamento desempenha um papel chave na modulação das usinas hidrelétricas, crucial em um cenário de intensa integração de fontes renováveis não despacháveis, como eólica e solar, cuja variabilidade acentua a complexidade do atendimento à da curva de carga líquida. Na Figura 29 e. é apresentada a curva diária de armazenamento do Submercado Sudeste/Centro-Oeste, para o período que vai de 2018 até 2022. Quando se trata de armazenamento, esse submercado é o mais importante de todos por contemplar reservatórios que juntos representam cerca de 70% da capacidade total de armazenamento do SIN no ano de 2024.

#### 4.4.6. ENERGIA NATURAL AFLUENTE

A Energia Natural Afluente (ENA) é uma variável de sistemas hidrelétricos que mensura a capacidade de transformação do fluxo de água em eletricidade, através do uso de instalações hidrelétricas. A ENA é determinada pela multiplicação das vazões naturais pela capacidade de produção por  $m^3/s$  (produtibilidade), assumindo o nível dos reservatórios hidrelétricos em 65% de seu volume útil. Esse cálculo, adaptável a intervalos temporais variados — seja diário, semanal, mensal ou anual —, também se estende a análises por bacia hidrográfica e por subsistema elétrico [239]. Na Figura 29 f. são apresentadas as séries temporais de ENA diária para cada um dos quatro submercados do SIN (Sudeste/Centro-Oeste, Sul, Nordeste e Norte), séries que contabilizadas as contribuições dos aproveitamentos internos a cada submercado de 2018 até 2022.

---

---

## 4.5. RESULTADOS

### 4.5.1. DESIGN DE EXPERIMENTOS

Esta seção apresenta os principais resultados obtidos com os experimentos conduzidos neste estudo, que investiga o uso de vários tipos de redes neurais artificiais na previsão dos preços da energia convencional no submercado Sudeste. Centenas de redes neurais dos tipos MLP, RNN, LSTM, GRU, BRNN, BLSTM e BGRU foram treinadas e avaliadas, considerando variações no número de *hidden layers* e neurônios, além de combinações distintas de preditores baseados em dados históricos da operação do sistema elétrico e do mercado de energia brasileiro. Os testes foram realizados utilizando uma janela móvel de um dia, ao longo de um período de aproximadamente um ano, de 01/03/2021 a 24/02/2022. Este intervalo foi escolhido por ter sido um período particularmente desafiador para o mercado livre de energia brasileiro, devido à crise hídrica e à alta volatilidade dos preços. Para cada uma das sete arquiteturas de redes contempladas neste estudo, foi analisada a influência dos preditores e das configurações dos parâmetros de rede na performance das previsões. Um destaque particular foi dado às redes que alcançaram o menor valor de erro absoluto médio; adicionalmente, foram avaliadas outras métricas de acurácia, eficiência, concordância e correlação, bem como o retorno financeiro que seria obtido caso suas previsões fossem utilizadas para a tomada de posição no mercado livre de energia brasileiro.

### 4.5.2. PERFORMANCE POR TIPO DE REDE NEURAL

A Tabela 12 apresenta os valores das métricas MAE, MAPE, *bias*, RMSE, NSE, *d* e *r* para as sete arquiteturas de redes neurais analisadas neste estudo. O objetivo é determinar qual arquitetura oferece a melhor performance preditiva, avaliando os resultados de cada métrica e verificando se as variações de desempenho entre modelos são expressivas. Basicamente, as métricas analisadas podem ser agrupadas em dois conjuntos principais: as de acurácia preditiva (MAE, MAPE, viés, RMSE), que quantificam os desvios das previsões em relação aos valores observados, onde valores mais baixos sugerem melhores resultados, com exceção do *bias*, cujo valor ideal é zero; e as de eficiência, concordância e correlação (NSE, *d*, *r*), que avaliam aspectos além da acurácia das previsões, em que valores próximos a 1 são considerados ideais.

Os resultados obtidos com as métricas MAE, MAPE e *bias* indicam que a BRNN gera previsões mais acuradas e menos enviesadas que os demais modelos avaliados. O MAE obtido para essa arquitetura foi de 13,172 R\$/MWh, valor próximo ao que foi obtido para outras

---

arquitecturas, como a MLP e a GRU. Com relação ao MAPE, todos os modelos avaliados produziram previsões classificadas como altamente precisas, caracterizadas por um MAPE inferior a 10%, de acordo com a escala definida por Chen *et al.* [89]. Notavelmente, a arquitectura BRNN se destaca, alcançando um MAPE de 4,555%, o que indica uma precisão superior em comparação aos demais modelos analisados. Quanto ao *bias* associado a essa rede, o valor obtido também foi o menor, -0,639 R\$/MWh, podendo ser considerado não significativo se tomarmos como referência a magnitude dos preços da energia convencional verificados para o período de teste (2021). Os valores de *bias* calculados para as demais configurações de rede também apresentam magnitude baixa, não excedendo -3 R\$/MWh. No entanto, quando são avaliadas as métricas de erro RMSE e MSE, que tem como característica a penalização intensa de desvios de previsão de maior intensidade, a indicação do tipo de rede que apresenta a melhor performance preditiva muda. A arquitectura GRU apresenta a melhor performance preditiva com os valores de 26,801 R\$/MWh e 718,287 R\$<sup>2</sup>/MWh<sup>2</sup> em termos de RMSE e MSE, seguida pelas redes MLP e BRNN no *ranking*, respectivamente.

Os coeficientes de eficiência (NSE), concordância (d) e correlação (r) estão alinhados com os resultados obtidos pelas métricas de erro RMSE e MSE. Especificamente, o NSE apresenta valores sempre superiores a 0,75 para o conjunto de redes avaliadas, refletindo um desempenho classificado como muito bom. O índice de Willmott, mantendo-se acima de 0,99, demonstra uma elevada concordância das previsões com os preços reais da energia convencional. Além disso, os valores da estatística r, consistentemente acima de 0,9, indicam uma correlação positiva extremamente alta. Com base nos resultados sumarizados na Tabela 12, fica evidente que a rede GRU se destaca no grupo. Dentre as oito métricas selecionadas para mensurar o desempenho dos modelos, cinco delas demonstram que a arquitectura GRU é superior e realiza melhores previsões. Isso resulta em erros menores, maior eficiência, melhor concordância entre previsões e observações, além de correlações mais fortes.

Tabela 12 - Resultados da avaliação dos modelos usando métricas de erro, eficiência e correlação.

Modelo	MAE [R\$/MWh]	MAPE [%]	<i>Bias</i> [R\$/MWh]	RMSE [R\$/MWh]	MSE [R\$ <sup>2</sup> /MWh <sup>2</sup> ]	NSE	d	r
MLP	13,782	4,855	1,094	27,288	744,616	0,965	0,991	0,983
RNN	14,716	5,243	0,700	27,614	762,537	0,963	0,991	0,982
LSTM	15,017	5,084	-2,320	28,956	838,427	0,959	0,990	0,981
GRU	13,846	4,766	-1,293	26,801	718,287	0,966	0,992	0,983
BRNN	13,172	4,555	-0,639	27,568	759,996	0,965	0,991	0,982
BLSTM	17,163	6,088	-2,114	29,589	875,496	0,958	0,990	0,980
BGRU	14,175	4,799	-2,792	27,903	778,593	0,963	0,991	0,982

De fato, as redes neurais do tipo GRU são uma variação eficiente das redes neurais recorrentes, projetadas para compreender relações em sequências de dados. Uma das principais vantagens das GRUs é sua capacidade de capturar dependências de longo prazo dentro dos dados de entrada. Isso é possível graças à sua estrutura de portões, que ajuda a controlar o fluxo de informações, permitindo que a rede retenha ou esqueça informações ao longo do tempo. Isso é particularmente útil em tarefas onde o contexto ou estado anterior é crucial para entender os dados atuais ou futuros. Em comparação com as redes LSTM, que também possuem uma estrutura de gerenciamento de fluxo de dados via portões, as redes GRUs se diferenciam pela estrutura simplificada com menos elementos, facilitando a implementação e reduzindo o tempo de treinamento. Sua capacidade de lidar com tamanhos variáveis de entrada e boa generalização as torna uma escolha robusta e versátil para modelagem de sequências, fato que pode explicar o desempenho superior observado para essa arquitetura nos experimentos conduzidos no presente estudo.

A fim de avaliar como mudanças estruturais afetam a performance da rede GRU, foram realizados testes considerando a variação da quantidade de camadas, número de neurônios por camada, preditores, bem como o número de *lags* consideradas. Os gráficos na Figura 30 apresentam o comportamento das métricas MAE, MAPE, *bias* e RMSE quando há mudanças no número de *layers* e de neurônios por camada. Nos gráficos, os valores foram ordenados do menor para o maior de acordo com o tipo de métrica e característica da arquitetura sendo avaliada. Os resultados indicam que menores valores de erro e enviesamento são obtidos quando o número de camadas é igual a 3 (01 *input*, 01 *hidden* e 01 *output layer*), em comparação a 4 (01 *input*, 02 *hidden* e 01 *output layer*). Ao comparar as curvas, observa-se que a amplitude dos erros é menor nas configurações em que a rede GRU possui 3 camadas. Por exemplo, para o caso do MAPE, a curva de erros para 3 camadas fica abaixo de 6%, enquanto na configuração com 4 camadas, os erros chegam a ultrapassar 8%. Quanto à influência do número de neurônios por camada, nota-se que um valor intermediário de 150 neurônios produz resultados mais acurados. No entanto, a comparação entre as curvas também revela que a amplitude dos erros para 300 neurônios é próxima à de 150, embora a performance seja inferior. Diferenças mais notáveis são observadas na comparação com a curva de 60 neurônios, que apresenta erros mais elevados, indicando que esse número de unidades não é ideal (ou insuficiente) para a previsão de preços de mercado. De forma geral, observa-se que uma estrutura de complexidade intermediária (3 *layers* e 150 neurônios no *hidden layer*) performa mais que estruturas com mais (e menos) elementos.

As previsões de Preço EC realizadas pela rede GRU com menor valor de MAE são apresentadas nos gráficos da Figura 31. Estes gráficos exibem, para cada um dos 6 meses do horizonte, tanto as curvas de previsão quanto as do valor real do Preço EC, incluindo também a diferenças entre elas. Os resultados mostram que, de forma geral, a rede GRU consegue realizar

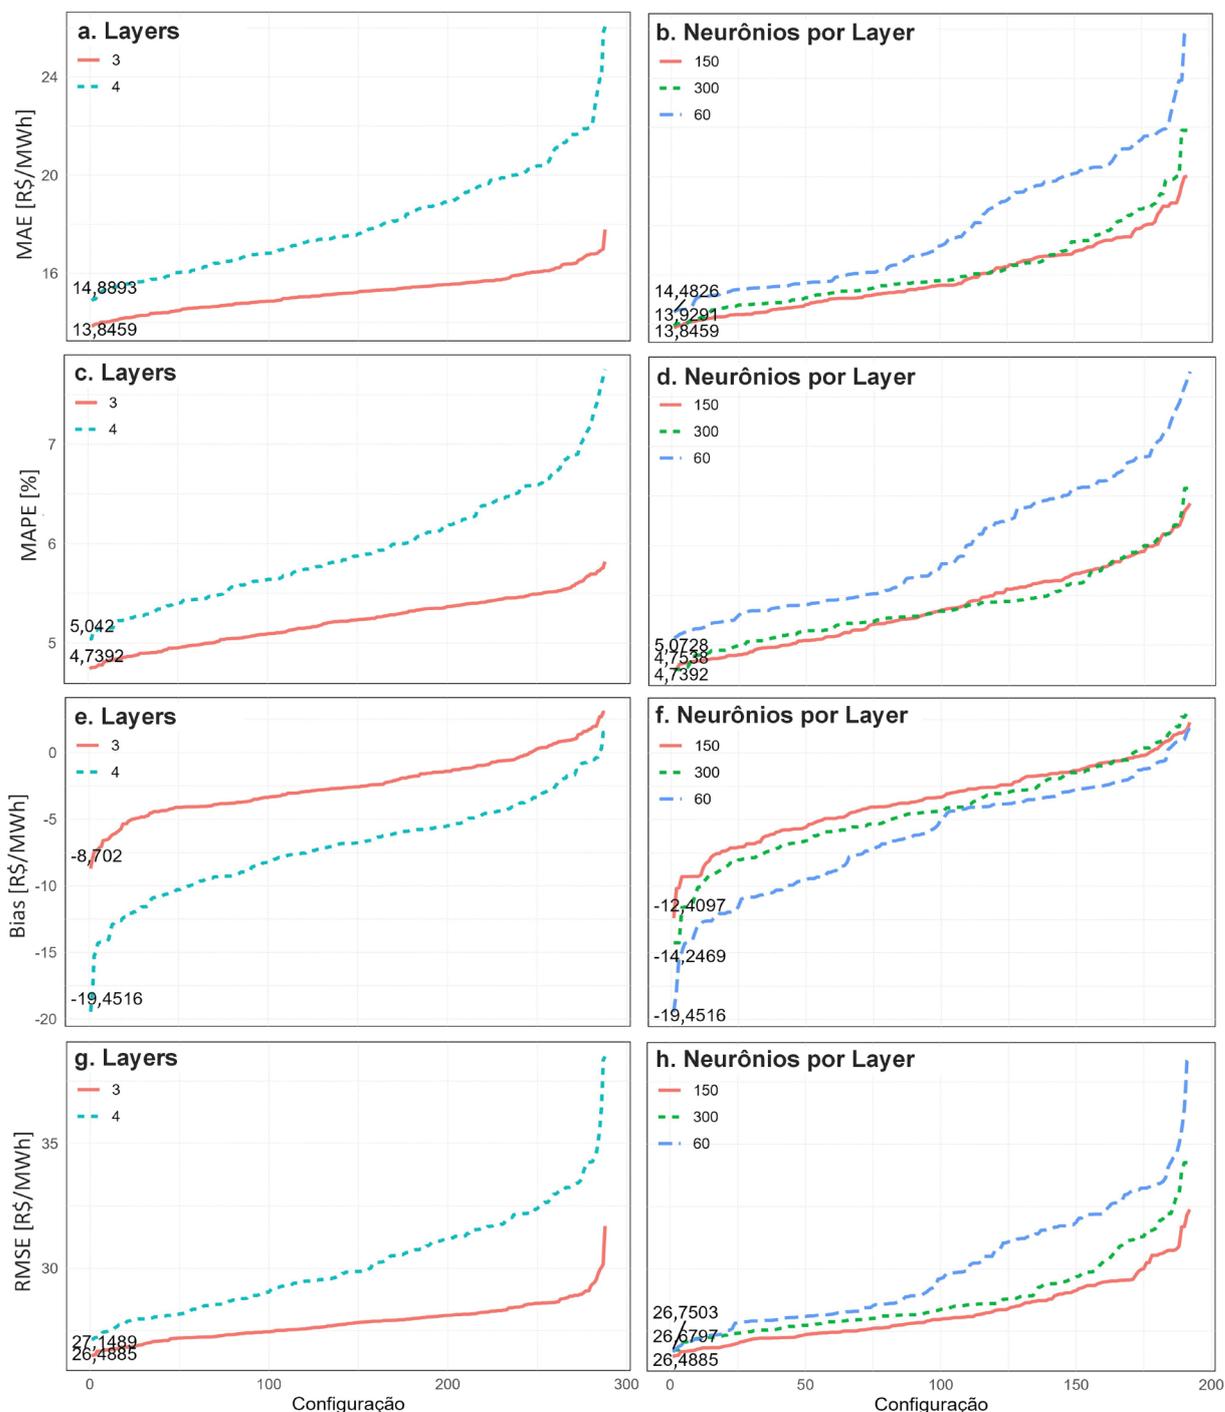


Figura 30 - Curvas das métricas de erro MAE, MAPE, Bias e RMSE considerando diferentes configurações para a rede GRU, isto é, variando o número de camadas e neurônios, assim como as combinações de preditores utilizados.

---

previsões aderentes à curva real de Preço EC, sendo capaz de acompanhar as tendências e variações observadas diariamente ao longo do período de teste (01/03/2021 a 24/02/2022, cerca de 1 ano). Observando o comportamento dos desvios representados pelas barras nos 6 gráficos, nota-se que os maiores valores são registrados quando o Preço EC atinge níveis mais elevados, bem como quando apresenta maior volatilidade, isto é, incrementos e decrementos mais acentuados. Em relação às séries temporais dos meses 3 a 6, os desvios não demonstram uma tendência clara de serem consistentemente positivos ou negativos. Por outro lado, ao analisar as curvas dos meses 1 e 2, nota-se uma alteração nesse padrão: as previsões tendem a subestimar o Preço EC, como evidenciado pela prevalência de desvios negativos nas ocasiões em que o preço alcança níveis mais elevados. Esse padrão pode ser explicado pelo comportamento singular dos preços EC no período seco de 2021, que foram os maiores registrados no histórico considerado neste estudo (ver Figura 29, item a.). Como o ano de 2021 foi o ano de teste e, conseqüentemente, não foi incluído no conjunto de treinamento/validação das redes neurais, a rede GRU enfrenta uma maior dificuldade na previsão de preços com um padrão de valores superior ao dos dados utilizados na etapa de aprendizado, resultando no viés apresentado na Tabela 12.

---

### 4.5.3. IMPACTO DOS PREDITORES

Seguindo uma abordagem similar à dos gráficos na Figura 30, a Figura 32, de a. a e., apresenta curvas de MAE para a arquitetura de rede GRU. Elas foram geradas considerando diversas combinações de quantidade de *layers*, número de neurônios por camada, tipos de preditores, bem como número máximo de *lags*. O foco dos gráficos, no entanto, é nos preditores (carga, EArm, PLD, ENA e Preço EC) e na quantidade de informações históricas admitidas (isto é, os últimos 14 ou 7 registros das séries históricas até o momento da previsão, sendo que no caso “NA”, nenhum registro foi considerado). Nessas curvas, os valores de MAE computados para as diversas configurações de rede GRU foram organizados de acordo com os critérios mencionados anteriormente, e posteriormente classificados do menor para o maior valor a fim de facilitar o processo de interpretação dos erros calculados. Os resultados apresentados de a. a d., indicam que a inclusão de dados históricos de carga, EArm, PLD e ENA não contribuem para a elevação da

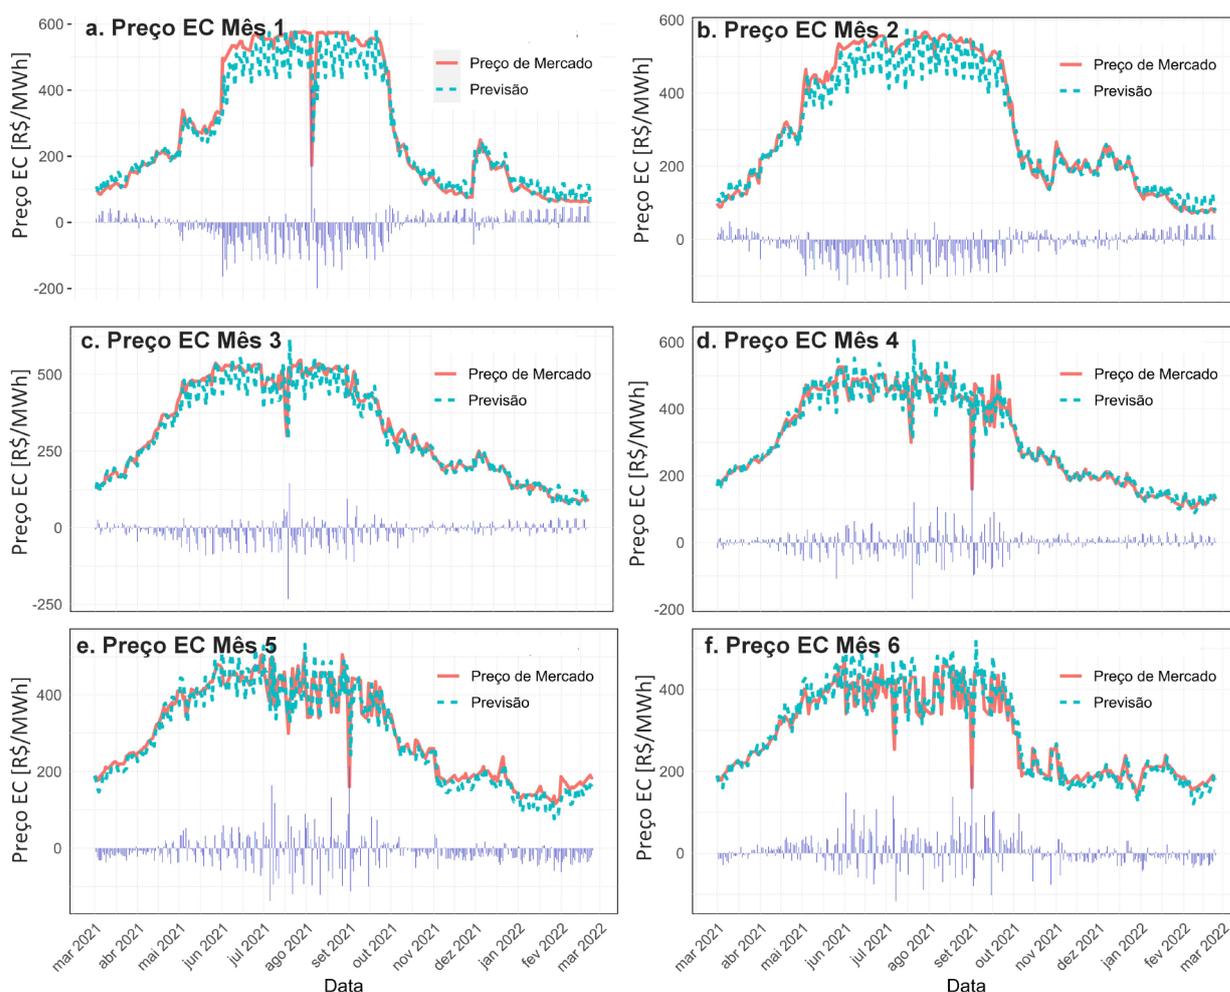


Figura 31 - Previsões do Preço EC realizadas pela rede GRU, considerando um horizonte de 6 meses à frente.

acurácia das previsões realizadas pelas redes neurais do tipo GRU. De fato, o que se observa, é um *range* de erros mais amplos quando são considerados *lags* que vão até 7 ou 14. Nesses casos, o MAE pode ultrapassar 25 R\$/MWh, enquanto no caso em que os dados são desconsiderados (*i.e.*, “NA”) o MAE não ultrapassa o valor de 16 R\$/MWh. Quanto ao Preço EC (ver Figura 32, item e.), observa-se que os melhores resultados são obtidos quando a *lag* máxima de dados históricos considerados é maior, no caso, igual a 14, indicando que a série temporal de preços carrega informações e padrões que, de fato, são relevantes para a previsão. No caso especial da ENA, também foi realizada uma avaliação considerando dados históricos dos submercados “Sudeste”, “Sudeste e Sul” e “Sudeste, Sul, Nordeste e Norte” (ver Figura 32, item f.). Observa-

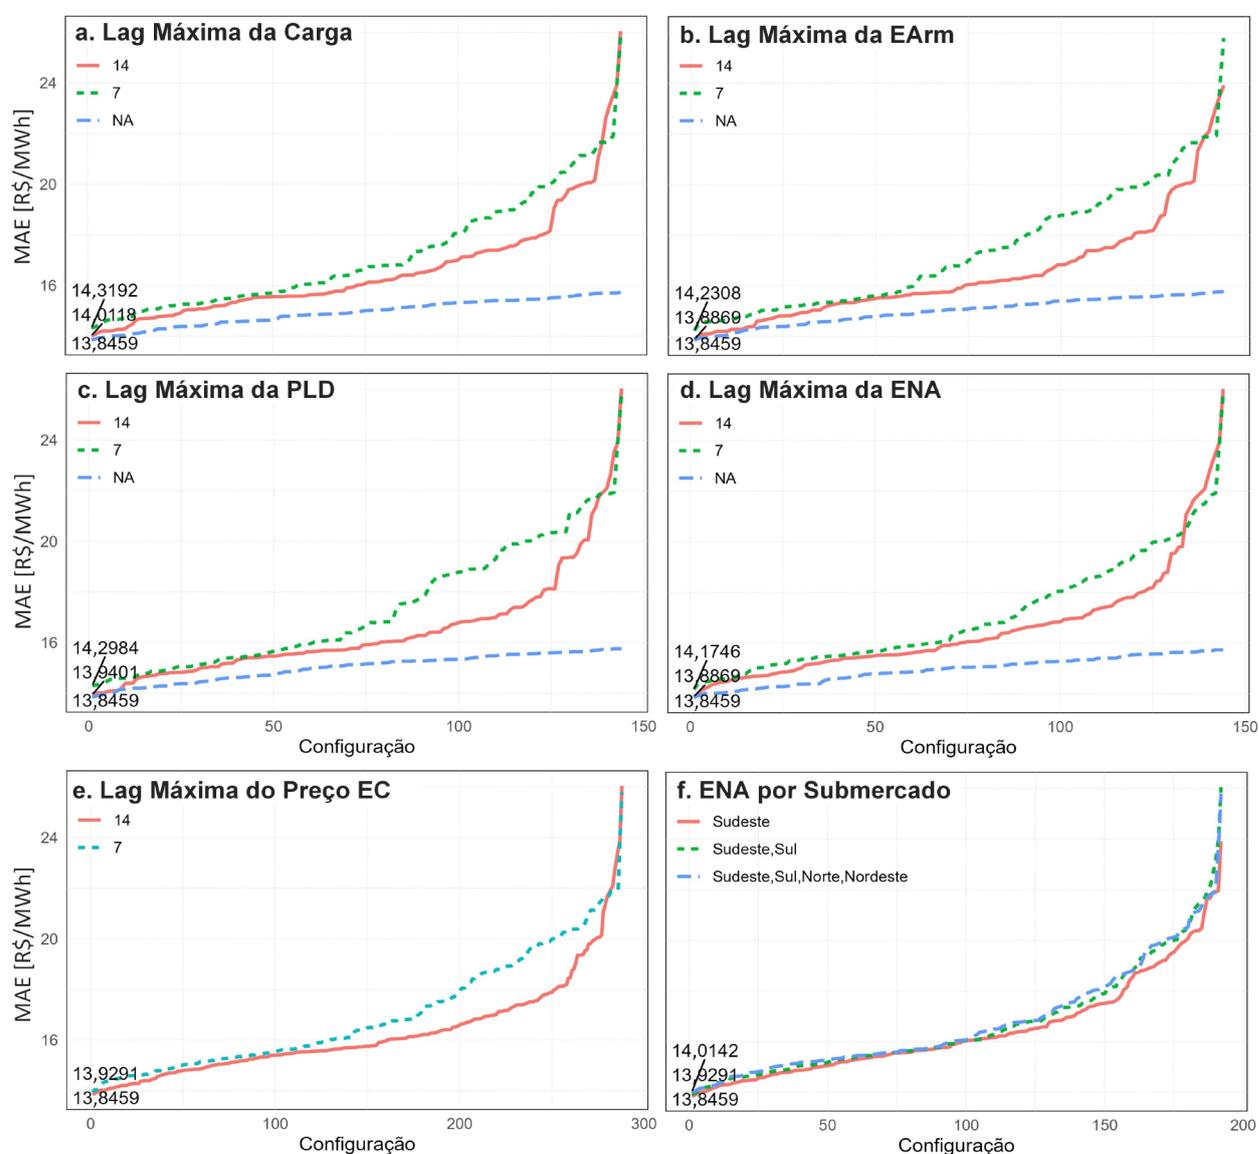


Figura 32 - Curvas da métrica MAE calculada considerando diferentes configurações de redes GRU, variando a combinação de preditores bem como as *lags* consideradas.

se que as curvas são similares, o que indica que a variação do tipo de ENA histórica utilizada não influencia de forma significativa no range dos erros calculados.

#### 4.5.4. TESTE DE HIPÓTESES DE DIEBOLD-MARIANO

Com a definição das redes neurais do tipo MLP, RNN, LSTM, GRU, BRNN, BLSTM e BGRU que apresentam os menores valores de MAE para o período de teste (ver Figura 30), procedeu-se à aplicação do Teste de Hipóteses de Diebold-Mariano. O teste estatístico avalia se alguma das redes neurais selecionadas gera previsões significativamente mais acuradas que as demais redes, considerando um nível de significância estatística de 5% (ou  $\alpha = 0,05$ ). Em outras palavras, o teste verifica se uma diferença observada na acurácia das previsões entre dois modelos pode ser considerada fruto do acaso ou se reflete uma vantagem real de um modelo sobre o outro. Conforme detalhado na Tabela 11, a interpretação dos resultados do teste é baseada no *p-value*. Valores inferiores a 0,05 indicam que o Modelo 1 é significativamente mais acurado, enquanto valores superiores a 0,95 indicam o contrário, isto é, o Modelo 2 supera o Modelo 1. Caso o valor do *p-value* seja intermediário a 0,05 e 0,95, não é possível concluir que as previsões de uma determinada rede neural são mais acuradas que as da rede concorrente. Na Tabela 13 são apresentados os resultados do teste aplicado entre pares de redes neurais. No total, foram avaliados 21 conjuntos de 2 elementos (temos 7 redes, e o número total de combinações possíveis é  $\frac{7!}{(7-2)!2!} = 21$ ). Os *p-values* calculados indicam que a rede do tipo GRU gera previsões estatisticamente mais acuradas de Preço EC (conforme pode ser conferido nos destaques em verde da tabela), superando outras redes em todas as análises comparativas par a par. Seguindo o *ranking*, a rede BRNN ocupa

Tabela 13 - Resultados da avaliação dos modelos usando o Teste de Hipóteses de Diebold-Mariano.

Par	Modelo 1	Modelo 2	<i>p-value</i>	+ Acurado	Par	Modelo 1	Modelo 2	<i>p-value</i>	+ Acurado
1	MLP	RNN	0,9321	--	11	RNN	BGRU	0,0000	RNN
2	MLP	LSTM	0,0011	MLP	12	LSTM	GRU	1,0000	GRU
3	MLP	GRU	1,0000	GRU	13	LSTM	BRNN	1,0000	BRNN
4	MLP	BRNN	0,9987	BRNN	14	LSTM	BLSTM	0,0000	LSTM
5	MLP	BLSTM	0,0000	MLP	15	LSTM	BGRU	0,0000	LSTM
6	MLP	BGRU	0,0000	MLP	16	GRU	BRNN	0,0029	GRU
7	RNN	LSTM	0,0001	RNN	17	GRU	BLSTM	0,0000	GRU
8	RNN	GRU	1,0000	GRU	18	GRU	BGRU	0,0000	GRU
9	RNN	BRNN	0,9831	BRNN	19	BRNN	BLSTM	0,0000	BRNN
10	RNN	BLSTM	0,0000	RNN	20	BRNN	BGRU	0,0000	BRNN
					21	BLSTM	BGRU	1,0000	BGRU

o segundo lugar, destacando-se por gerar previsões mais acuradas que as outras arquiteturas, exceto a GRU (conforme indicado pelas marcações em azul). Os resultados da Tabela 13 concordam com aqueles obtidos na Tabela 12, em que as redes GRU e BRNN são apontadas como as redes de melhor desempenho.

#### 4.5.5. AVALIAÇÃO DE ESTRATÉGIAS DE ATUAÇÃO

No dinâmico e cada vez mais competitivo mercado de energia, a capacidade de prever com precisão os movimentos de preços constitui uma vantagem estratégica fundamental para agentes comercializadores. A tomada de decisão informada, baseada em análises preditivas confiáveis, pode significar a diferença entre lucros substanciais e oportunidades perdidas. Neste contexto, o emprego de redes neurais surge como uma ferramenta poderosa, oferecendo *insights* preditivos relevantes. Com o objetivo de compreender o impacto da aplicação desses modelos no mercado de energia, e como suas previsões podem servir de alicerce para a formação de estratégias e a otimização da posição de agentes comercializadores, é proposto um exercício que visa mensurar o retorno financeiro pautado na atuação de um agente fictício que pratica *trading direcional overnight* (*i.e.*, o agente adota posição *long*, de compra, se acredita que o preço vai subir, ou posição *short*, de venda, se espera que ele vai cair, buscando lucrar com essas movimentações) no mercado de energia brasileiro ao longo do período de teste das redes neurais (01/03/2021 a 24/02/2022, cerca de 1 ano).

Neste contexto, considere a perspectiva de um agente comercializador que deseja lucrar com a venda (ou compra) de 1MWh de energia para cada mês do horizonte abarcado pelas previsões de Preço EC via redes neurais (*i.e.*, 6MWh por negócio). O agente fictício toma posição diariamente seguindo a estratégia de atuação definida pelas seguintes regras pautadas na previsão feita por uma determinada rede neural para o dia seguinte,  $Preço_{d+1,prev}$  (expectativa de *Curva Forward* de preços para o dia seguinte), e os preços que estão sendo observados no dia corrente,  $Preço_{d,merc}$ :

- Se a expectativa é de que os preços do dia seguinte sejam inferiores aos do dia corrente,  $Preço_{d+1,prev} < Preço_{d,merc}$ , o agente comercializador opta por vender o bloco de energia no dia  $d$  pelo preço  $Preço_{d,merc}$ . No dia seguinte, o agente comercializador compra esse mesmo volume de energia pelo preço oficial de mercado  $Preço_{d+1,merc}$  (esse volume serve para cobrir a venda que foi realizada no

dia anterior, lembrando que o horizonte de suprimento dessa energia é para os 6 meses seguintes à venda);

- Por outro lado, se a expectativa é de que os preços do dia seguinte sejam superiores ao do dia corrente,  $Preço_{d+1,prev} > Preço_{d,merc}$ , o agente comercializador opta por comprar o bloco de energia no dia  $d$  pelo preço  $Preço_{d,merc}$ , de forma que no dia seguinte esse mesmo bloco seja vendido pelo preço oficial de mercado  $Preço_{d+1,merc}$ .

Vale ressaltar que nesse experimento adota-se a premissa de que não existem custos de transação e que o mercado possui liquidez, isto é, a energia é amplamente negociada e disponível para compra e venda, permitindo que as posições sejam facilmente abertas e fechadas. Assim, as estratégias desenvolvidas com base nas previsões das redes neurais podem ser implementadas sem a preocupação de alterações significativas nos preços devido a dificuldades de execução das ordens. Esse cenário idealizado assegura que os resultados obtidos reflitam o puro desempenho das estratégias de previsão e decisão, sem a influência de fatores externos como custos adicionais ou a necessidade de considerar a dinâmica de oferta e demanda específica de momentos de baixa liquidez.

O Retorno Financeiro Diário ( $RF_D$ ) de acordo com a realização do mercado e a estratégia adotada é computado da seguinte forma:

- Se o agente comercializador optar por vender o bloco de energia no dia  $d$ , o retorno financeiro com relação a compra realizada no dia  $d + 1$  é dado pela expressão (45). Observe que ele é calculado com base nos preços de mercado. Os preços previstos pela rede neural servem apenas para amparar a tomada de decisão do agente comercializador.

$$RF_D = (Preço_{d,merc} - Preço_{d+1,merc}) \times Energia Transacionada \quad (45)$$

- Em contrapartida, se o agente comercializador optar por comprar o bloco de energia no dia  $d$ , o retorno financeiro com relação a venda realizada no dia  $d + 1$  é dado pela expressão (46).

$$RF_D = (Preço_{d+1,merc} - Preço_{d,merc}) \times Energia Transacionada \quad (46)$$

Considerando que o agente atuou no mercado ao longo de  $D$  dias, o Retorno Financeiro Acumulado (RF) é dado por (47), onde  $e_d$  é uma variável binária que assume o valor 1 quando o agente comercializador opta por comprar energia no dia  $d$  ou o valor  $-1$  quando o agente opta por vender energia no dia  $d$ .

$$RF = \sum_{d=1}^D e_d \times (Preço_{d+1,merc} - Preço_{d,merc}) \times Energia Transacionada \quad (47)$$

Com relação às previsões de preço utilizadas no experimento para o cálculo do retorno financeiro, foram consideradas três vertentes de estratégias de previsão:

- **Neural Network Strategy:** previsões realizadas utilizando as redes neurais artificiais MLP, RNN, LSTM, GRU, BRNN, BLSTM e BGU com melhores resultados (as mesmas cujas estatísticas foram abordadas na Tabela 12);
- **Momentum-Based Strategy (MB):** a tendência média de crescimento ou decréscimo dos preços entre os dias  $d - 1$  e  $d$  é calculada, e o valor resultante é aplicado aos preços estabelecidos no dia  $d$ . Este procedimento é utilizado para formular uma previsão dos preços para o dia  $d + 1$ , baseando-se na variação média observada entre os dois dias anteriores;
- **Randon Guessing Strategy (RG):** similar ao caso anterior, com a diferença de que o sinal da tendência aplicada aos preços do dia  $d$ , para a previsão dos preços do dia  $d + 1$ , é alterado aleatoriamente;
- **Previsão Perfeita (PP):** para efeito de comparação e avaliação do potencial do retorno financeiro das estratégias anteriores, foi considerada uma estratégia fictícia em que o agente comercializador acerta os preços com 100% de acurácia.

A Tabela 14 reúne os principais resultados obtidos quando se considera as previsões de preço realizadas pelas redes neurais artificiais e pelas estratégias MB e RG. A tabela destaca a) o retorno financeiro total (RF Total), que contabiliza os ganhos e perdas acumulados até o final do período de teste (01/03/2021 a 24/02/2022, cerca de 1 ano); b) o retorno financeiro médio diário (RF Médio Diário), que consiste nos ganhos e perdas acumulados divididos pelo total de dias de operação no mercado; c) o desvio padrão do retorno financeiro diário (Desvio Padrão do RF); e d) a acurácia da previsão do movimento dos preços (Acurácia da Previsão de Mov.), ou seja, razão com que as previsões indicam corretamente o sentido do movimento dos preços de um dia para o outro.

Os resultados mostram que a rede neural do tipo LSTM é a que gera o maior retorno financeiro acumulado total, no valor de 4.356 R\$, seguida pelas redes BGRU, BLSTM e GRU. A média diária associada à arquitetura mais lucrativa é de 12,17 R\$, com um desvio padrão (que representa a variabilidade) em 93,51 R\$, o menor de todos (sem considerar, é claro, os resultados da coluna PP). Apesar do retorno financeiro obtido com essa arquitetura ser o mais elevado, é notável que ainda há margem de aperfeiçoamento, visto que esse valor representa aproximadamente 22,3% daquele que foi obtido com PP. Em relação às estratégias alternativas testadas, MB e RG, observa-se que a primeira, apesar de sua lógica simples, conseguiu gerar um retorno financeiro positivo ao final do período analisado. Este retorno, embora significativamente inferior ao obtido pela rede LSTM, foi surpreendentemente superior ao da rede RNN. Em contrapartida, a estratégia RG levou a um retorno financeiro acumulado negativo, o pior do grupo e com a maior variabilidade diária de retornos financeiros, sugerindo que definir aleatoriamente a direção do movimento dos preços não constitui uma estratégia eficaz para obtenção de lucros no mercado de energia.

A Figura 33 apresenta a evolução temporal do retorno financeiro acumulado para as redes neurais e as estratégias MB e RG. Enquanto as redes LSTM, BRNN, MLP e RNN exibem um retorno financeiro acumulado sempre positivo ao longo do tempo, as redes GRU, BLSTM, BGRU, juntamente com as estratégias MG e RG, registram períodos de retorno negativo, especialmente na primeira metade de suas curvas. Apesar do acumulado total ser sempre superior a zero para esse conjunto de quatro redes neurais financeiramente mais promissoras (considerando um período de teste de 01/03/2021 a 24/02/2022), é notável que ao longo do eixo temporal o comportamento das curvas varia bastante. No caso da BRNN, por exemplo, observa-se um crescimento contínuo, sem grandes variações, que aparenta perder força na segunda metade da curva. Já no caso da LSTM, inicialmente observa-se uma tendência de elevação dos valores acumulados, que é revertida em seguida, para então, voltar a apresentar crescimento de forma mais acelerada. A Figura 34 a. ilustra a sobreposição dessas duas curvas com a aquela que seria obtida em uma “operação perfeita”, que poderia ser alcançada caso as previsões de preço fossem também perfeitas (PP). As variações observadas nas curvas de retorno refletem a performance oscilante das redes ao longo do tempo. Em determinados períodos, as redes demonstram uma performance superior, acelerando o acúmulo de receita; já em outros momentos, a performance diminui, resultando nos vales evidentes nas curvas de retorno.

A relação entre o retorno financeiro e a performance das redes (em termos de previsão de movimentos de preço) é complexa e interessante de se avaliar. A acurácia da previsão de

movimentos de preço, apresentada na última linha da Tabela 14, mostra que, surpreendentemente, a estratégia MB tem o maior coeficiente de acertos, cerca de 0,6369, sendo que o máximo é 1. Em contraste, a arquitetura LSTM ocupa a terceira posição, com um coeficiente de 0,5698, enquanto a BRNN registra 0,5754. Este resultado indica que um elevado coeficiente de acerto de movimentos de preços, como no caso da estratégia MB, não necessariamente se traduz no maior retorno financeiro acumulado. Isso se deve ao fato de que o retorno financeiro, conforme descrito na expressão (47), depende do termo  $(Preço_{d+1,merc} - Preço_{d,merc})$ . Tomadas de posição assertivas que envolvem maiores diferenças entre os preços de compra e venda (ou venda e compra) resultam em maiores retornos. O histograma apresentado na Figura 34 b. mostra que, para o caso da estratégia MB, a maioria dos retornos positivos ocorre na classe com menor amplitude de retorno financeiro diário (i.e., de 0 a 50 R\$), com percentual bem acima do que é observado para as redes LSTM e BRNN. Essa concentração na classe de menor amplitude explica o fato da estratégia MB não ser tão lucrativa apesar da acurácia na previsão e movimentos de preço.

#### 4.5.6. OBSERVAÇÕES E DISCUSSÃO

A contribuição do presente estudo consiste no desenvolvimento de redes neurais artificiais com arquiteturas sofisticadas para a previsão do preço de produtos mensais do tipo energia convencional do Sudeste, com maturidade de até 6 meses, no mercado livre de energia brasileiro. Centenas de redes neurais do tipo MLP, RNN, LSTM, GRU, BRNN, BLSTM e BGRU foram treinadas e avaliadas considerando variações no número de *hidden layers* e neurônios, além de combinações distintas de preditores baseados em dados históricos da operação do sistema elétrico e do mercado de energia brasileiro. O conjunto de preditores utilizados neste estudo abrange uma variedade de dados, incluindo carga, energia natural afluyente, armazenamento de

Tabela 14 - Retorno financeiro e acurácia da previsão de movimentos de preço.

	MLP	RNN	LSTM	GRU	BRNN	BLSTM	BGRU	MB	RG	PP
RF Total [R\$]	2.280	829	4.356	2.646	2.309	3.156	3.662	1.636	-779	19.535
RF Médio Diário [R\$]	6,37	2,31	12,17	7,39	6,45	8,82	10,23	4,57	-2,18	54,57
Desvio Padrão do RF Diário [R\$]	94,09	94,28	93,51	94,01	94,08	93,89	93,75	94,10	94,19	76,86
Acurácia da Prev. de Mov.	0,5503	0,5363	0,5698	0,5223	0,5754	0,5251	0,5363	0,6369	0,4974	1,0000

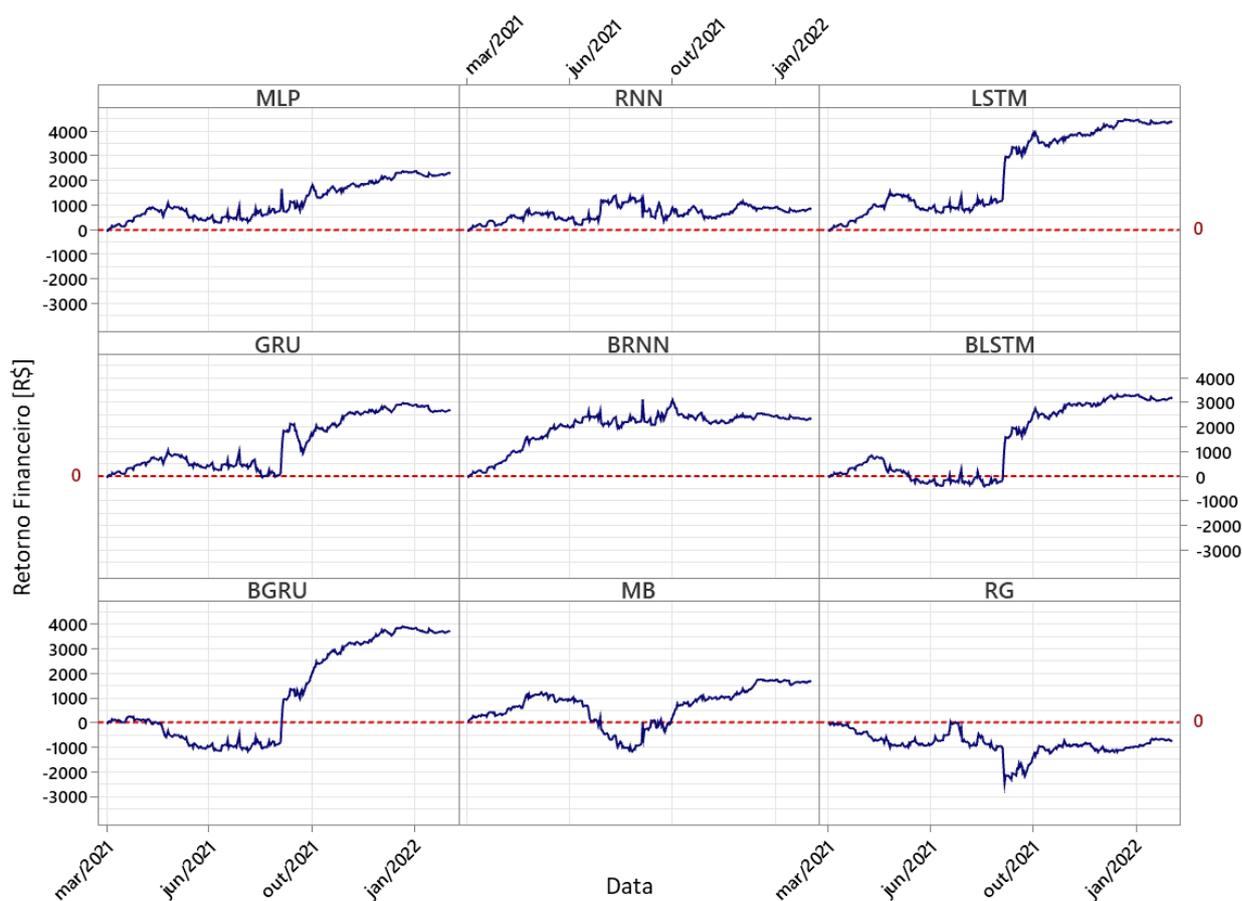


Figura 33 - Retorno financeiro acumulado ao longo do horizonte temporal de teste.

energia, preço da energia nos negócios firmados no ambiente de livre comercialização, bem como aquele calculado pelo operador de mercado para a liquidação da energia não coberta por contratos.

Os resultados do estudo demonstram que, dentre as arquiteturas analisadas, a GRU apresenta desempenho preditivo superior. Esta arquitetura obteve os menores valores de RMSE e MSE, registrando 26,801 R\$/MWh e 718,287 R<sup>2</sup>/MWh<sup>2</sup>, respectivamente, além de apresentar valores de MAE, MAPE e bias em 13,846 R\$/MWh, 4,766% e -1,293 R\$/MWh. O teste de hipóteses de Diebold-Mariano corrobora esse resultado, evidenciando estatisticamente que as previsões do modelo GRU são mais acuradas que as dos demais modelos. Adicionalmente, as métricas que avaliam eficiência (NSE = 0,966), concordância (d = 0,992) e correlação (d = 0,983) entre previsões e valores históricos dos produtos no mercado livre de energia também reforçam a superioridade da rede GRU.

Além da análise da acurácia preditiva dos modelos testados, o estudo também demonstra que a aplicação das previsões das redes neurais na formação de estratégias de tomada de posição no mercado de energia é capaz de gerar retornos financeiros positivos. O experimento revelou que,

apesar da arquitetura GRU apresentar a melhor performance preditiva de preços, foi a rede LSTM quem gerou o maior valor acumulado de retorno financeiro ao final do período de teste. Além disso, é importante frisar que a acurácia desta rede na previsão dos movimentos de preço (*i.e.*, se os preços irão aumentar ou diminuir) também se mostrou superior à das demais redes avaliadas.

Outros estudos nessa mesma linha de pesquisa, mas voltados para a previsão de movimentos de preço de diferentes tipos de ativos em mercados internacionais, também demonstram que a aplicação de modelos de *Machine Learning* consegue gerar previsões de movimento de preço com acurácia superior a 50%, geralmente concentrada no intervalo de 50-60%, servindo como ferramentas úteis para a tomada de decisão no mercado. Isso é corroborado, por exemplo, por Gerlein *et al.* (2016) [197] e Yildirim *et al.* (2021) [198], que abordam, respectivamente, o caso das moedas USD/JPY e EUR/USD no FOREX, e por Ibrahim *et al.* (2021) [199], que explora a criptomoeda Bitcoin. No âmbito nacional, destacam-se os estudos desenvolvidos por Santos *et al.* (2022) [209] e Castilho Braz *et al.* (2024) [210] focados na previsão de movimentos do preço da energia convencional no mercado livre de energia brasileiro usando o algoritmo *Random Forest*.

Em comparação aos estudos prévios, o presente trabalho avança e se diferencia por explorar de forma mais profunda diversas arquiteturas de redes neurais, das clássicas MLP e RNN às mais atuais e complexas LSTM, GRU, BRNN, BLSTM e BGRU, no problema de previsão de preços no mercado livre de energia brasileiro. Além disso, é relevante frisar que nesse processo de

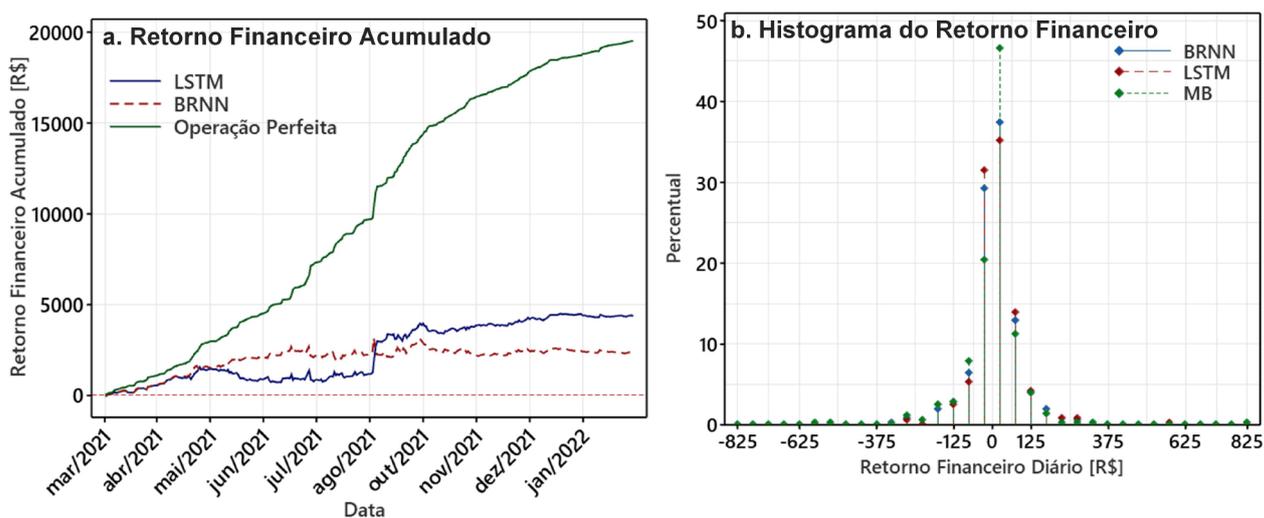


Figura 34 - O gráfico (a.) apresenta o retorno financeiro diário acumulado quando o agente comercializador toma decisões com base no preço previsto pelas redes LSTM e BRNN, bem como quando a operação no mercado de energia é “perfeita”. Já em (b.), é feita uma comparação entre os histogramas de retorno financeiro diário considerando os preços previstos pelas redes LSTM, BRNN e pela estratégia *Momentum-Based*.

---

análise das arquiteturas citadas, também foi realizada uma vasta exploração da combinação de preditores fundamentados em dados históricos do sistema elétrico e mercado de energia brasileiro, revelando que os modelos que utilizam apenas os preços da energia convencional tendem a apresentar melhor performance preditiva.

Essa importante limitação revelada pelo estudo fundamenta a ideia de que os agentes do mercado de energia, ao realizarem suas negociações de compra e venda de energia convencional, formam preço levando em consideração a expectativa de evolução temporal (ou melhor, as projeções) das variáveis que definem o estado do sistema elétrico brasileiro e do mercado livre de energia. No caso, seriam essas mudanças de expectativa um dos principais *drivers* do preço negociado para o horizonte considerado no presente estudo. Nesse contexto, é de conhecimento geral que os agentes de mercado costumam realizar estudos prospectivos que partem de previsões de precipitação geradas por modelos de previsão de tempo (para o curto prazo, até uns 15 dias à frente) e de clima (para o médio prazo, ou seja, meses à frente). Os dados de precipitação futura são utilizados como *inputs* em modelos que transformam chuva em vazão, servindo de insumo para o cálculo da ENA, bem como em estudos prospectivos de PLD.

Além da chuva, a expectativa futura de carga e outras variáveis, tais como geração renovável das usinas eólicas, solares, bem como a de pequenas centrais hidrelétricas e termelétricas, exercem influência significativa sobre os preços negociados pelos agentes no mercado de energia, principalmente por conta da especulação que ocorre nos dias que precedem as grandes revisões oficiais dos dados considerados pelos modelos de planejamento da operação do SIN (*i.e.*, as revisões quadrimestrais). Adicionalmente, as restrições operativas do SIN, principalmente aquelas relacionadas a usinas hidrelétricas estratégicas para o planejamento da operação do sistema, tais como Jupia e Porto Primavera, bem como usinas do Rio São Francisco, costumam impactar o resultado dos estudos prospectivos realizados pelos agentes de mercado e, conseqüentemente, os preços negociados. Durante períodos de crise hídrica, quando há possibilidade do Comitê de Monitoramento do Setor Elétrico determinar um regime de operação especial para determinadas usinas por motivos de segurança energética, o mercado de energia é frequentemente afetado pelas especulações que precedem o anúncio de medidas oficiais e a forma como serão implementadas.

De forma geral, pode-se afirmar que são diversos os fatores que atuam como *drivers* dos movimentos do preço da energia convencional negociada no mercado livre de energia elétrica brasileiro. Algum desses *drivers* podem ser internalizados pelas redes neurais por meio de preditores, como ocorre para o caso das previsões de ENA baseadas na execução de modelos

---

---

chuva-vazão alimentados com dados de modelos climáticos. No entanto, a especulação do mercado com relação a variáveis como carga, geração renovável, e restrições operativas relevantes representam um desafio a ser superado. De fato, a evolução das técnicas de modelagem via redes neurais artificiais e a integração de informações que fazem parte do processo de tomada de decisão dos agentes são essenciais para o refinamento das previsões de preço. Este estudo representa um avanço nessa direção, especialmente no que se refere à aplicação de estruturas de redes neurais mais avançadas. No entanto, ainda existe amplo espaço para futuros aprimoramentos que possam continuar a refinar e expandir as capacidades preditivas destes modelos.

## 4.6. CONCLUSÃO

A previsão de preços de ativos em mercados é um problema importante e complexo na literatura que investiga aplicações práticas de *Machine Learning* e inteligência artificial. No mercado livre de energia brasileiro, a problemática da previsão dos preços negociados entre os agentes é ainda mais complexa, dada a gama de fatores que influenciam o processo de tomada de decisão de quem atua comprando e vendendo energia. A fim de contribuir nesse sentido, o presente estudo avalia a aplicação de redes neurais clássicas, tais como MLP e RNN, e mais avançadas, incluindo LSTM, GRU, BRNN, BLSTM e BGRU, na previsão do preço da energia convencional, considerando produtos com maturidade de até 6 meses.

O estudo comparou diversas arquiteturas de redes neurais para previsão de preços no mercado livre de energia, constatando que a GRU se destacou com o menor RMSE e MSE, valores de 26,801 R\$/MWh e 718,287 R\$<sup>2</sup>/MWh<sup>2</sup>, respectivamente, e indicadores de acurácia como MAE, MAPE e bias também favoráveis, bem como os melhores valores para as métricas NSE,  $d$  e  $r$ . Além disso, o Teste de Hipóteses de Diebold-Mariano confirmou estatisticamente a superioridade das previsões da GRU sobre outros modelos considerando um nível de significância estatística de 5% ( $\alpha = 0,05$ ). No entanto, a rede LSTM, apesar de não ser a melhor em termos de acurácia preditiva, proporcionou o maior retorno financeiro acumulado durante o período de teste, evidenciando sua proficiência em antecipar movimentos de preço, superando a maioria das demais redes neurais artificiais na previsão de tendências de aumento ou redução do valor da energia.

Dado os resultados promissores obtidos, estudos futuros devem explorar quatro vertentes principais: a) a aplicação de outros modelos de *Machine Learning* e redes neurais, tais como *Transformer Neural Networks* e *Bayesian Neural Networks*, na previsão dos preços da energia convencional; b) o uso de previsões de carga e ENA na formação de preditores para os modelos,

---

---

sendo que, no caso da ENA, a vazão dos aproveitamentos do SIN seria calculada utilizando modelos chuva-vazão forçados com dados de previsão de precipitação sazonal (horizonte de meses à frente) com atualização diária; c) a exploração de técnicas para a composição de *Multi-model Ensembles*, visto que a combinação de modelos com características distintas tende a gerar previsões mais robustas por compensar as fraquezas de um modelo com as forças de outro, reduzindo a probabilidade de erros sistemáticos; e d) a gestão do risco atrelado à tomada de posição no mercado utilizando as previsões feitas pelos modelos baseados em inteligência artificial.

---

## 4.7. APÊNDICE

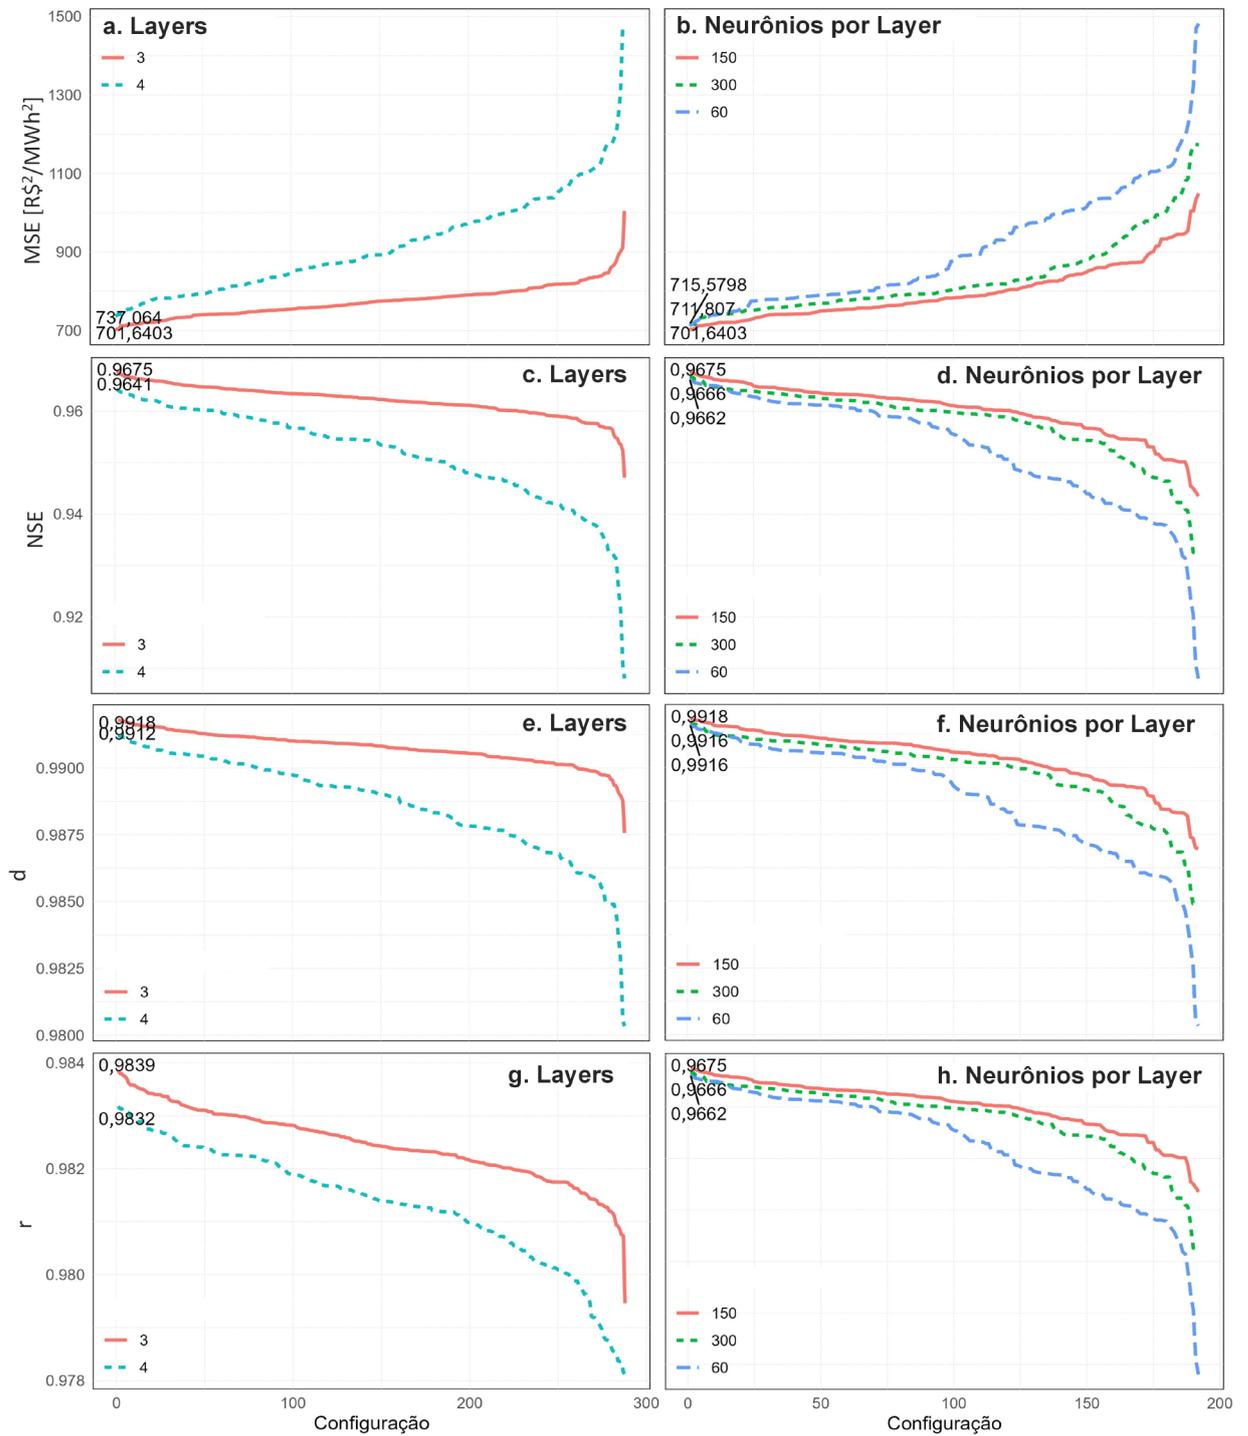


Figura 35 - Curvas das métricas MSE, NSE, d e r considerando diferentes configurações de redes GRU, variando o número de camadas e neurônios, assim como as combinações de preditores utilizados.

---

# CAPÍTULO 5

## CONCLUSÃO GERAL

### 5.1. OBSERVAÇÕES FINAIS

O objetivo desta pesquisa de doutoramento é propor um conjunto de soluções para problemas que afetam os agentes comercializadores de energia que estabelecem estratégias de atuação no mercado livre de energia elétrica brasileiro. Basicamente, duas vertentes de pesquisa são exploradas: a) o aprimoramento das previsões de variáveis hidrológicas (vazões e precipitação) essenciais para o entendimento de como as condições do SIN podem evoluir; e b) a previsão da *Curva Forward* de preços que reflete as tendências dos preços efetivamente negociados pelos agentes no ACL.

No que tange à primeira vertente, devido à predominância da fonte hidráulica na matriz elétrica brasileira e a sua forte relação com preço da energia, as previsões de variáveis hidrológicas são extremamente importantes para a realização de estudos que apoiam o processo de tomada de decisão. Apesar dos agentes serem dependentes desse tipo de previsão, as metodologias frequentemente adotadas para a realização de previsões de variáveis hidrológicas não são ideais (há margem para aprimoramento), principalmente no caso do médio prazo em que as séries temporais históricas de precipitação e vazão são recorrentemente utilizadas como cenários futuros.

No contexto dos preços estabelecidos pelos agentes, embora algoritmos de *Machine Learning* sejam amplamente utilizados na previsão de preços e suas flutuações em mercados internacionais de ações, câmbio e criptomoedas, a aplicação dessas técnicas para a previsão da *Curva Forward* de preços no Brasil ainda não foi extensivamente explorada, especialmente através de arquiteturas mais avançadas de *Artificial Neural Networks*. O mercado livre de energia brasileiro possui dinâmicas complexas e multifatoriais que as técnicas avançadas de *Machine Learning* têm potencial de compreender e considerar em suas previsões.

Em ambas as vertentes citadas, a) e b), existem questões em aberto que podem ser aprimoradas a fim de tornar o processo de tomada de decisão por parte dos agentes mais robusto. Neste âmbito, a presente tese de doutorado apresenta duas contribuições relacionadas ao processo

---

---

de previsão de variáveis hidrológicas e uma contribuição com foco na previsão da *Curva Forward* de preços:

- Aprimoramento da previsão de vazão a curto prazo através da aplicação de BMA a um MME:

Foi proposto e implementado um *framework* em que os membros de um MME são combinados via pesos calculados com base nas distribuições de probabilidade corrigidas com dados observados. Essa abordagem proporciona a contabilização da incerteza estrutural no processo de previsão de vazões, o que contribui para a criação de previsões mais robustas. Os pesos aplicados para o cálculo da BMA são dinâmicos, ou seja, são recalculados com a entrada de novos dados nas séries temporais de vazões observadas e previstas a fim de captar o comportamento recente das cadeias chuva-vazão. Além disso, os membros que efetivamente participam do ensemble são selecionados através da aplicação do princípio de *Occam's Razor* que descarta as cadeias com baixa performance antes do cálculo da BMA. Os resultados obtidos para a métrica DM indicam que a aplicação da metodologia proposta consegue gerar *em média* previsões melhores que os membros individuais, principalmente nos primeiros dias do horizonte temporal de previsão.

- Aprimoramento da previsão sazonal de precipitação sobre o Brasil através da aplicação de técnicas de ML:

Foi proposto um *framework* baseado em MLR e SVM que gera modelos individuais para cada célula de uma grade sobre o Brasil utilizando os índices climáticos associados aos padrões de teleconexão, a análise de precipitação do CPC e as previsões de precipitação do SEAS5 como preditores. Os resultados obtidos demonstram que em relação ao modelo SEAS5, os modelos MLR e SVM são capazes de aumentar a acurácia e reduzir o viés das previsões de precipitação nas regiões Sudeste, Centro-Oeste e Norte do Brasil no trimestre DJF, enquanto nas regiões Nordeste e Sul possuem performance similar. Além disso, a abordagem que utiliza SVM apresentou uma performance superior à da MLR em todas as regiões, sugerindo a existência de uma relação não linear entre a precipitação e o conjunto de preditores adotados neste estudo.

- Previsão da *Curva Forward* de preços usando *Artificial Neural Networks*:
-

---

Foi avaliada a aplicação de redes neurais do tipo MLP, RNN, BRNN, LSTM, BLSTM, GRU e BGRU considerando variações estruturais na arquitetura de cada uma delas, além da influência de preditores exógenos relacionadas à operação do SIN e do ACL, tais como Energia Natural Afluentes aos aproveitamentos hidroelétricos, carga do Submercado SE/CO, nível de armazenamento dos reservatórios do Submercado SE/CO e o Preço de Liquidação das Diferenças do Submercado SE/CO. Os resultados mostram que a rede neural GRU apresenta a melhor performance preditiva em termos de acurácia, eficiência, concordância e correlação com os dados da série oficial de preços, gerando ainda previsões estatisticamente mais acuradas que as das demais arquiteturas testadas. Apesar dos resultados obtidos com a GRU, experimentos adicionais mostram que a arquitetura LSTM foi capaz de superar a GRU quando se avalia o retorno financeiro acumulado por um agente comercialização que toma posições de compra e venda informadas pela rede neural sob análise.

## 5.2. ESTUDOS FUTUROS

Embora este estudo tenha fornecido avanços nas vertentes de pesquisa exploradas, reconhece-se a necessidade de investigações adicionais para expandir e aprofundar as descobertas apresentadas. Estudos futuros poderão explorar novas metodologias, ampliar o escopo das análises e incluir variáveis adicionais nos modelos testados. Dessa forma, delineiam-se diversas direções que podem ser seguidas para o aprofundamento da compreensão do tema e o desenvolvimento contínuo do campo, tais como:

- A aplicação de outros algoritmos, além de MLR e SVM, para o aprimoramento da previsão sazonal de precipitação, tais como *Random Forest*, *Logistic Regression*, *K-Nearest Neighbor Regression*, *Gradient Boosting* e *Artificial Neural Networks*;
  - A aplicação de técnicas de decomposição de séries temporais, tais como transformada *Wavelet*, nos dados de precipitação histórica utilizados para a previsão sazonal de precipitação;
  - A aplicação de outros algoritmos de *Machine Learning* e redes neurais, tais como *Transformer Neural Networks* e *Bayesian Neural Networks*, na previsão da *Curva Forward de preços*;
-

- A avaliação do uso de previsões de carga, geração eólica/solar e ENA como preditores nas redes neurais artificiais que preveem a *Curva Forward* de preços, sendo que, no caso da ENA, a vazão dos aproveitamentos do SIN seria calculada utilizando modelos chuva-vazão forçados com dados de previsão de precipitação sazonal (horizonte de meses à frente) com atualização diária;
- A aplicação de técnicas de *Multi-Model Ensemble* para a previsão da *Curva Forward* de preços, visto que a combinação de modelos com características distintas tende a gerar previsões mais robustas por compensar as fraquezas de um modelo com as forças de outro, reduzindo a probabilidade de erros sistemáticos;
- A gestão do risco atrelado à tomada de posição no mercado utilizando as previsões de preço feitas pelos modelos baseados em *Machine Learning*, bem como avaliação de outras estratégias de comercialização além do *Trading Direcional Overnight*.

### 5.3. PUBLICAÇÕES

A seguir, são apresentadas as publicações resultantes do período de pesquisa associado à elaboração desta tese:

- **Paper 01** (Publicado no *Water Journal*): "*Integrating Hydrological and Machine Learning Models for Enhanced Streamflow Forecasting via Bayesian Model Averaging in a Hydro-Dominant Power System*". Artigo relacionado ao Capítulo 2 da presente tese de doutorado.
- **Paper 02** (Publicado na *RBMET*): "*Refining Seasonal Precipitation Forecast in Brazil Using Simple Data-Driven Techniques and Climate Indices*". Artigo relacionado ao Capítulo 3 da presente tese de doutorado.
- **Paper 03** (Publicado na *RBCLIM*): "*Seasonal Climate Forecast 'Drivers': A Literature Review*". Artigo relacionado ao Capítulo 3 da presente tese de doutorado.
- **Paper 04** (Revista a ser definida): "*Forecasting Energy Market Prices using Neural Networks: A Brazilian Free Market Environment Case Study*". Artigo relacionado ao Capítulo 4 da presente tese de doutorado.

---

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] EPE, “Balanço Energético Nacional: Relatório Síntese 2023 (ano base 2022)”, Rio de Janeiro, 2023.
  - [2] ONS, “O Sistema em Números”. Acessado: 1º de maio de 2024. [Online]. Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>
  - [3] E. L. da Silva e E. C. Finardi, “Planning of hydrothermal systems using a power plant individualistic representation”, em *2001 IEEE Porto Power Tech Proceedings*, 2001. doi: 10.1109/PTC.2001.964890.
  - [4] CEPEL, “Long and medium term operation planning model for interconnected hydrothermal systems”. Acessado: 23 de novembro de 2020. [Online]. Disponível em: [http://www.cepel.br/en\\_us/products/newave-long-and-medium-term-operation-planning-model-for-interconnected-hydrothermal-systems-1.htm](http://www.cepel.br/en_us/products/newave-long-and-medium-term-operation-planning-model-for-interconnected-hydrothermal-systems-1.htm)
  - [5] CEPEL, “Short term operation planning model for interconnected hydrothermal systems”. Acessado: 28 de novembro de 2020. [Online]. Disponível em: [http://www.cepel.br/en\\_us/products/decomp-short-term-operation-planning-model-for-interconnected-hydrothermal-systems-1.htm](http://www.cepel.br/en_us/products/decomp-short-term-operation-planning-model-for-interconnected-hydrothermal-systems-1.htm)
  - [6] CEPEL, “Short term hydrothermal dispatch model”. Acessado: 28 de novembro de 2020. [Online]. Disponível em: [http://www.cepel.br/en\\_us/products/dessem-short-term-hydrothermal-dispatch-model-1.htm](http://www.cepel.br/en_us/products/dessem-short-term-hydrothermal-dispatch-model-1.htm)
  - [7] J. G. Tundisi, “Water resources in the future: problems and solutions”, *Estudos Avançados*, vol. 22, nº 63, p. 7–16, 2008, doi: 10.1590/S0103-40142008000200002.
  - [8] M. Cheng, F. Fang, T. Kinouchi, I. M. Navon, e C. C. Pain, “Long lead-time daily and monthly streamflow forecasting using machine learning methods”, *J Hydrol (Amst)*, vol. 590, p. 125376, 2020, doi: 10.1016/j.jhydrol.2020.125376.
  - [9] E. Schmitt Quedi e F. Mainardi Fan, “Sub seasonal streamflow forecast assessment at large-scale basins”, *J Hydrol (Amst)*, vol. 584, p. 124635, 2020, doi: 10.1016/j.jhydrol.2020.124635.
  - [10] S. Sohrabi, F. P. Brissette, e R. Arsenault, “Coupling large-scale climate indices with a stochastic weather generator to improve long-term streamflow forecasts in a Canadian watershed”, *J Hydrol (Amst)*, vol. 594, p. 125925, 2020, doi: 10.1016/j.jhydrol.2020.125925.
  - [11] F. das N. R. da Silva, J. L. D. Alves, e M. Cataldi, “Climate downscaling over South America for 1971–2000: application in SMAP rainfall-runoff model for Grande River Basin”, *Clim Dyn*, vol. 52, nº 1–2, p. 681–696, 2019, doi: 10.1007/s00382-018-4166-7.
  - [12] H. L. Cloke e F. Pappenberger, “Ensemble flood forecasting: A review”, *J Hydrol (Amst)*, vol. 375, nº 3–4, p. 613–626, set. 2009, doi: 10.1016/j.jhydrol.2009.06.005.
-

- 
- [13] D. Draper, “Assessment and propagation of model uncertainty”, *Journal of the Royal Statistical Society*, vol. 57, n° 1, p. 45–97, 1995, doi: 10.2307/2346087.
- [14] D. R. Bourdin e R. B. Stull, “Bias-corrected short-range member-to-member ensemble forecasts of reservoir inflow”, *J Hydrol (Amst)*, vol. 502, n° 2013, p. 77–88, 2013, doi: 10.1016/j.jhydrol.2013.08.028.
- [15] Z. Zahmatkesh, M. Karamouz, e S. Nazif, “Uncertainty based modeling of rainfall-runoff: Combined differential evolution adaptive metropolis (DREAM) and K-means clustering”, *Adv Water Resour*, vol. 83, p. 405–420, 2015, doi: 10.1016/j.advwatres.2015.06.012.
- [16] N. K. Ajami, Q. Duan, e S. Sorooshian, “An integrated hydrologic Bayesian multimodel combination framework: Confronting input, parameter, and model structural uncertainty in hydrologic prediction”, *Water Resour Res*, vol. 43, n° 1, p. 1–19, 2007, doi: 10.1029/2005WR004745.
- [17] K. Bahramian, R. Nathan, A. W. Western, e D. Ryu, “Towards an ensemble-based short-term flood forecasting using an event-based flood model- incorporating catchment-average estimates of soil moisture”, *J Hydrol (Amst)*, vol. 593, p. 125828, fev. 2021, doi: 10.1016/j.jhydrol.2020.125828.
- [18] B. O. Brito, R. M. Salgado, e L. A. Beijo, “Intelligent modeling for streamflow forecasting”, *IEEE Latin America Transactions*, vol. 14, n° 8, p. 3669–3677, 2016, doi: 10.1109/TLA.2016.7786349.
- [19] V. A. Siqueira, F. M. Fan, R. C. D. de Paiva, M. H. Ramos, e W. Collischonn, “Potential skill of continental-scale, medium-range ensemble streamflow forecasts for flood prediction in South America”, *J Hydrol (Amst)*, vol. 590, n° February, p. 125430, 2020, doi: 10.1016/j.jhydrol.2020.125430.
- [20] V. H. A. Ribeiro, G. Reynoso-Meza, e H. V. Siqueira, “Multi-objective ensembles of echo state networks and extreme learning machines for streamflow series forecasting”, *Eng Appl Artif Intell*, vol. 95, p. 103910, out. 2020, doi: 10.1016/j.engappai.2020.103910.
- [21] B. Sabzipour, R. Arsenault, e F. Brissette, “Evaluation of the potential of using subsets of historical climatological data for ensemble streamflow prediction (ESP) forecasting”, *J Hydrol (Amst)*, p. 125656, 2020, doi: 10.1016/j.jhydrol.2020.125656.
- [22] K. Beven, *Rainfall-Runoff Modelling: The Primer*, 2° ed. Willey-Blackwell, 2012. doi: 10.1002/9781119951001.
- [23] S. K. Singh, “Long-term streamflow forecasting based on ensemble streamflow prediction technique: A case study in New Zealand”, *Water Resources Management*, vol. 30, n° 7, p. 2295–2309, 2016, doi: 10.1007/s11269-016-1289-7.
- [24] ONS, “O Sistema Interligado Nacional”. Acessado: 28 de novembro de 2020. [Online]. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>
- [25] ONS, “Diagrama esquemático das usinas hidroelétricas do SIN”. Acessado: 28 de novembro de 2020. [Online]. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/mapas>
-

- 
- [26] J. Coiffier, *Fundamentals of Numerical Weather Prediction*. Cambridge University Press, 2011.
- [27] ONS, “NT 149/2007: Novo modelo de previsão de vazões com informação de precipitação para a bacia do Rio Iguaçu”, Rio de Janeiro, 2007.
- [28] ONS, “NT 174/2007: Novo Modelo de Previsão de Vazões com Informação de Precipitação para o Trecho Incremental Itumbiara - São Simão”, Rio de Janeiro, 2007.
- [29] ONS, “NT 153/2010: Previsão de vazões incrementais diárias na bacia do Rio São Francisco usando a técnica de redes neurais”, Rio de Janeiro, 2010.
- [30] ONS, “Relatório Final 141/2011: Aplicação de modelos de previsão de vazão a curto prazo na sub-bacia do Baixo Rio Grande”, Rio de Janeiro, 2011.
- [31] ONS, “Relatório Final 153/2012: Aplicação de modelos de previsão de vazão a curto prazo na sub-bacia do Alto Rio Paranaíba”, Rio de Janeiro, 2012.
- [32] ONS, “NT 173/2007: Novo modelo de previsão de vazões com informação de precipitação para o trecho incremental de Itaipu”, Rio de Janeiro, 2007.
- [33] ONS, “NT 97/2018-RV4: Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN”, Rio de Janeiro, 2020.
- [34] S. C. Chou, “Modelo regional ETA”, *Climanálise - Boletim de Monitoramento e Análise Climática*, edição especial comemorativa de 10 anos, art. 27, 1996, Acessado: 31 de maio de 2024. [Online]. Disponível em: <http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/27.html>
- [35] S. C. Chou e M. G. A. J. da Silva, “Objective evaluation of Eta model precipitation forecasts”, *Climanálise - Boletim de Monitoramento e Análise Climática*, vol. 1, nº 1, p. 1–17, 1999, Acessado: 31 de maio de 2024. [Online]. Disponível em: [http://climanalise.cptec.inpe.br/~rclimanl/revista/pdf/ETA\\_Chou.pdf](http://climanalise.cptec.inpe.br/~rclimanl/revista/pdf/ETA_Chou.pdf)
- [36] X. Zhou, Y. Zhu, D. Hou, Y. Luo, J. Peng, e R. Wobus, “Performance of the new NCEP global ensemble forecast system in a parallel experiment”, *Weather Forecast*, vol. 32, nº 5, p. 1989–2004, 2017, doi: 10.1175/WAF-D-17-0023.1.
- [37] ONS, “NT 156/2016-RV5: Uso de previsão de precipitação por conjunto para a previsão de vazões da primeira semana operativa”, Rio de Janeiro, 2018.
- [38] ONS, “NT 53/2019: Metodologia de previsão de precipitação por conjunto e remoção de viés com histórico de curto prazo”, ONS, Rio de Janeiro, 2019.
- [39] ONS, “Ata da reunião do PMO de jul/2020”. Portal SINtegre, Rio de Janeiro, 2020.
- [40] ECMWF, “Set III - Atmospheric model Ensemble 15-day forecast (ENS)”, Real-time datasets. [Online]. Disponível em: <https://www.ecmwf.int/en/forecasts/datasets/set-iii>
- [41] D. Il Jeong e Y. O. Kim, “Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction”, *Hydrol Process*, vol. 19, nº 19, p. 3819–3835, 2005, doi: 10.1002/hyp.5983.
-

- 
- [42] K. S. Kasiviswanathan, R. Cibin, K. P. Sudheer, e I. Chaubey, “Constructing prediction interval for artificial neural network rainfall-runoff models based on ensemble simulations”, *J Hydrol (Amst)*, vol. 499, p. 275–288, ago. 2013, doi: 10.1016/j.jhydrol.2013.06.043.
- [43] S. V. Saraiva, F. de O. Carvalho, C. A. G. Santos, L. C. Barreto, e P. K. de M. M. Freire, “Daily streamflow forecasting in Sobradinho Reservoir using machine learning models coupled with wavelet transform and bootstrapping”, *Appl Soft Comput*, vol. 102, p. 107081, abr. 2021, doi: 10.1016/j.asoc.2021.107081.
- [44] A. Y. Shamseldin, K. M. O’Connor, e G. C. Liang, “Methods for combining the outputs of different rainfall-runoff models”, *J Hydrol (Amst)*, vol. 197, n° 1–4, p. 203–229, 1997, doi: 10.1016/S0022-1694(96)03259-3.
- [45] Y.-O. Kim, D. Jeong, e I. H. Ko, “Combining rainfall-runoff model outputs for improving ensemble streamflow prediction”, *J Hydrol Eng*, vol. 11, n° 6, p. 578–588, 2006, doi: 10.1061/(asce)1084-0699(2006)11:6(578).
- [46] N. Devineni, A. Sankarasubramanian, e S. Ghosh, “Multimodel ensembles of streamflow forecasts: Role of predictor state in developing optimal combinations”, *Water Resour Res*, vol. 44, n° 9, p. 1–22, 2008, doi: 10.1029/2006WR005855.
- [47] A. Muhammad, T. A. Stadnyk, F. Unduche, e P. Coulibaly, “Multi-model approaches for improving seasonal ensemble streamflow prediction scheme with various statistical post-processing techniques in the Canadian Prairie Region”, *Water (Basel)*, vol. 10, n° 11, 2018, doi: 10.3390/w10111604.
- [48] T. M. Fragoso, W. Bertoli, e F. Louzada, “Bayesian model averaging: A systematic review and conceptual classification”, *International Statistical Review*, vol. 86, n° 1, p. 1–28, 2018, doi: 10.1111/insr.12243.
- [49] A. E. Raftery, D. Madigan, e J. A. Hoeting, “Bayesian model averaging for linear regression models”, *J Am Stat Assoc*, vol. 92, n° 437, p. 179–191, 1997, doi: 10.1080/01621459.1997.10473615.
- [50] J. A. Hoeting, D. Madigan, A. E. Raftery, e C. T. Volinsky, “Bayesian model averaging: A tutorial”, *Statistical Science*, vol. 14, n° 4, p. 382–401, 1999, doi: 10.1214/ss/1009212519.
- [51] S. He, S. Guo, Z. Liu, J. Yin, K. Chen, e X. Wu, “Uncertainty analysis of hydrological multi-model ensembles based on CBP-BMA method”, *Hydrology Research*, vol. 49, n° 5, p. 1636–1651, 2018, doi: 10.2166/nh.2018.160.
- [52] M. B. Wagena *et al.*, “Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models”, *Environmental Modelling and Software*, vol. 126, p. 104669, 2020, doi: 10.1016/j.envsoft.2020.104669.
- [53] Q. Duan, N. K. Ajami, X. Gao, e S. Sorooshian, “Multi-model ensemble hydrologic prediction using Bayesian model averaging”, *Adv Water Resour*, vol. 30, n° 5, p. 1371–1386, 2007, doi: 10.1016/j.advwatres.2006.11.014.
-

- 
- [54] L. See e S. Openshaw, “A hybrid multi-model approach to river level forecasting”, *Hydrological Sciences Journal*, vol. 45, nº 4, p. 523–536, 2000, doi: 10.1080/02626660009492354.
- [55] F. de A. de Souza Filho *et al.*, “Enhancing streamflow forecasting for the Brazilian electricity sector: a strategy based on a hyper-multimodel”, *RBRH*, vol. 28, 2023, doi: 10.1590/2318-0331.282320230120.
- [56] ONS, “REL 142/2020: Atualização de séries históricas de vazões - período 1931 a 2019”, Rio de Janeiro, 2020.
- [57] ONS, “Historical time series of daily natural streamflows dataset”, Distributed by SINtegre. Acessado: 2 de março de 2023. [Online]. Disponível em: <https://sintegre.ons.org.br/sites/9/13/84>
- [58] ONS, “NT 144/2018: Metodologia de Reconstituição e Tratamento das Vazões Naturais”, Rio de Janeiro, 2018.
- [59] ONS, “Hydraulic-hydrological reports (dataset)”, Distributed by SINtegre. Acessado: 2 de março de 2023. [Online]. Disponível em: <https://sintegre.ons.org.br/sites/9/13/56/paginas/servicos/produtos.aspx>
- [60] NASA, “The Tropical Rainfall Measuring Mission”. Acessado: 27 de agosto de 2021. [Online]. Disponível em: <https://gpm.nasa.gov/missions/trmm>
- [61] J. R. Rozante, D. S. Moreira, L. G. G. de Goncalves, e D. A. Vila, “Combining TRMM and surface observations of precipitation: technique and validation over South America”, *Weather Forecast*, vol. 25, nº 3, p. 885–894, 2010, doi: 10.1175/2010WAF2222325.1.
- [62] NASA, “The Global Precipitation Measurement Mission”. Acessado: 29 de agosto de 2021. [Online]. Disponível em: <https://gpm.nasa.gov/missions/GPM>
- [63] J. R. Rozante, E. R. Gutierrez, A. de A. Fernandes, e D. A. Vila, “Performance of precipitation products obtained from combinations of satellite and surface observations”, *Int J Remote Sens*, vol. 41, nº 19, p. 7585–7604, 2020, doi: 10.1080/01431161.2020.1763504.
- [64] F. L. R. Torres *et al.*, “Validação de diferentes bases de dados de precipitação nas bacias hidrográficas do Sapucaí e São Francisco”, *Revista Brasileira de Climatologia*, vol. 27, p. 368–404, 2020, doi: 10.5380/abclima.v27i0.73634.
- [65] CPTEC, “MERGE data set”, CPTEC Data. [Online]. Disponível em: <http://ftp.cptec.inpe.br/modelos/tempo/MERGE/GPM/DAILY>
- [66] R. Kimura, “Numerical weather prediction”, *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 90, nº 12–15, p. 1403–1414, 2002, doi: 10.1016/S0167-6105(02)00261-1.
- [67] NOAA, “Global Ensemble Forecast System”. Acessado: 23 de novembro de 2020. [Online]. Disponível em: [https://www.emc.ncep.noaa.gov/emc/pages/numerical\\_forecast\\_systems/gefs.php](https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gefs.php)
-

- 
- [68] EMC, “Global Forecast System”, Environmental Modeling Center. Acessado: 22 de novembro de 2023. [Online]. Disponível em: [https://www.emc.ncep.noaa.gov/emc/pages/numerical\\_forecast\\_systems/gfs.php](https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs.php)
- [69] E. Gascón, T. Hewson, e T. Haiden, “Improving predictions of precipitation type at the surface: Description and verification of two new products from the ECMWF ensemble”, *Weather Forecast*, vol. 33, nº 1, p. 89–108, 2018, doi: 10.1175/WAF-D-17-0114.1.
- [70] W. Collischonn e C. E. M. Tucci, “Simulação hidrológica de grandes bacias”, *Revista Brasileira de Recursos Hídricos*, vol. 6, nº 1, p. 95–118, 2001, doi: 10.21168/rbrh.v6n1.p95-118.
- [71] W. Collischonn, D. Allasia, B. C. da Silva, e C. E. M. Tucci, “The MGB-IPH model for large-scale rainfall-runoff modelling”, *Hydrological Sciences Journal*, vol. 52, nº 5, p. 878–895, 2007, doi: 10.1623/hysj.52.5.878.
- [72] W. Collischonn, C. H. A. Gama, V. A. Siqueira, R. C. D. Paiva, e A. S. Fleischmann, “Manual de Referência Teórica do MGB”. HGE, IPH, UFRGS, Porto Alegre, 2020.
- [73] C. A. C. Kuki, F. L. R. Torres, V. A. D. de Faria, A. R. de Queiroz, L. M. M. Lima, e J. W. M. Lima, “Estratégias de Previsão de Vazão de Curto Prazo: um estudo de caso nas Bacias do Rio Grande e Rio Paranaíba”, em *Anais do XXIII Congresso Brasileiro de Automática*, Campinas: Sociedade Brasileira de Automática, 2020, p. 1–8. doi: 10.48011/asba.v2i1.1479.
- [74] C. A. C. Kuki, F. L. R. Torres, V. A. D. de Faria, A. R. De Queiroz, L. M. M. Lima, e J. W. M. Lima, “Estratégia de previsão de vazão para formação do preço de energia elétrica no curto prazo”, em *Anais do LII Simpósio Brasileiro de Pesquisa Operacional*, João Pessoa: Galoá, 2020, p. 1–12.
- [75] J. E. G. Lopes, B. P. F. Braga, e J. G. L. Conejo, “SMAP: A simplified hydrologic model”, em *Applied Modeling in Catchment Hydrology*, V.P.Singh, Org., Littleton, Colorado, USA: Water Resources Publications, 1982, p. 167–176.
- [76] ONS, “SMAP Data”, SINtegre. [Online]. Disponível em: <https://sintegre.ons.org.br/sites/9/13/82/pages/servicos/produtos.aspx>
- [77] ONS, “ONS 97/2018-RV7: Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN”, Rio de Janeiro, 2018.
- [78] W. S. McCulloch e W. H. Pitts, “A logical calculus of the ideas immanent in nervous activity”, *Bulletin of Mathematical Biophysics*, vol. 5, p. 115–133, 1943, doi: 10.1007/BF02478259.
- [79] F. Rosenblatt, “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychol Rev*, vol. 65, nº 6, p. 386–408, 1958, doi: 10.1037/h0042519.
- [80] D. E. Rumelhart, G. E. Hinton, e R. J. Williams, “Learning representations by back-propagating errors”, *Nature*, vol. 323, p. 533–536, 1986, doi: 10.1038/323533a0.
-

- 
- [81] A. Krogh, “What are artificial neural networks?”, *Nat Biotechnol*, vol. 26, n° 2, p. 195–197, 2008, doi: 10.1038/nbt1386.
- [82] V. A. D. de Faria, A. R. de Queiroz, L. M. Lima, J. W. M. Lima, e B. C. da Silva, “An assessment of multi-layer perceptron networks for streamflow forecasting in large-scale interconnected hydrosystems”, *International Journal of Environmental Science and Technology*, 2021, doi: 10.1007/s13762-021-03565-y.
- [83] M. Hinne, Q. F. Gronau, D. van den Bergh, e E.-J. Wagenmakers, “A conceptual introduction to Bayesian model averaging”, *Adv Methods Pract Psychol Sci*, vol. 3, n° 2, p. 200–215, 2020, doi: 10.1177/2515245919898657.
- [84] L. Wasserman, “Bayesian model selection and model averaging”, *J Math Psychol*, vol. 44, n° 1, p. 92–107, 2000, doi: 10.1006/jmps.1999.1278.
- [85] D. Kaplan e D. Sarah, “Bayesian Statistical Methods”, em *The Oxford Handbook of Quantitative Methods*, vol. 1, T. D. Little, Org., Nova York: Oxford University Press, 2013, p. 407–437.
- [86] T. K. Moon, “The expectation-maximization algorithm”, *IEEE Signal Process Mag*, vol. 13, n° 6, p. 47–60, 1996, doi: 10.1109/79.543975.
- [87] I. J. Myung, “Tutorial on maximum likelihood estimation”, *J Math Psychol*, vol. 47, n° 1, p. 90–100, 2003, doi: 10.1016/S0022-2496(02)00028-7.
- [88] G. E. P. Box e D. R. Cox, “An analysis of transformations”, *J Am Stat Assoc*, vol. 26, n° 2, p. 211–252, 1964, doi: 10.1111/j.2517-6161.1964.tb00553.x.
- [89] R. J. C. Chen, P. Bloomfield, e J. S. Fu, “An evaluation of alternative forecasting methods to recreation visitation”, *J Leis Res*, vol. 35, n° 4, p. 441–454, 2003, doi: 10.1080/00222216.2003.11950005.
- [90] J. E. Nash e J. V. Sutcliffe, “River flow forecasting through conceptual models part I - A discussion of principles”, *J Hydrol (Amst)*, vol. 10, n° 3, p. 282–290, 1970, doi: 10.1016/0022-1694(70)90255-6.
- [91] D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, e T. L. Veith, “Model evaluation guidelines for systematic quantification of accuracy in watershed simulations”, *Transactions of the ASABE 2007*, vol. 50, n° 3, p. 885–900, 2007, doi: 10.13031/2013.23153.
- [92] ONS, “Aplicativo SMAP: manual de metodologia”, Rio de Janeiro, 2017.
- [93] F. X. Diebold e R. S. Mariano, “Comparing predictive accuracy”, *Journal of Business and Economic Statistics*, vol. 13, n° 3, p. 253–263, 1995, doi: 10.1080/07350015.1995.10524599.
- [94] A. E. Raftery, T. Gneiting, F. Balabdaoui, e M. Polakowski, “Using Bayesian model averaging to calibrate forecast ensembles”, *Mon Weather Rev*, vol. 133, n° 5, p. 1155–1174, 2005, doi: 10.1175/MWR2906.1.
-

- 
- [95] I. K. de Almeida, A. K. Almeida, S. G. Gabas, e T. A. Sobrinho, “Performance of methods for estimating the time of concentration in a watershed of a tropical region”, *Hydrological Sciences Journal*, vol. 62, n° 14, p. 2406–2414, 2017, doi: 10.1080/02626667.2017.1384549.
- [96] G. E. P. Box e N. R. Draper, *Empirical Model-Building and Response Surfaces*, vol. 37, n° 1. John Wiley & Sons, Inc., 1987.
- [97] K. Smith, “The influence of weather and climate on recreation and tourism”, *Weather*, vol. 48, n° 12, p. 398–404, 1993, doi: 10.1002/j.1477-8696.1993.tb05828.x.
- [98] J. Schweighofer, “The impact of extreme weather and climate change on inland waterway transport”, *Natural Hazards*, vol. 72, n° 1, p. 23–40, 2014, doi: 10.1007/s11069-012-0541-6.
- [99] E. Chavez, G. Conway, M. Ghil, e M. Sadler, “An end-to-end assessment of extreme weather impacts on food security”, *Nat Clim Chang*, vol. 5, n° 11, p. 997–1001, 2015, doi: 10.1038/nclimate2747.
- [100] H. D. Shannon e R. P. Motha, “Managing weather and climate risks to agriculture in North America, Central America and the Caribbean”, *Weather Clim Extrem*, vol. 10, p. 50–56, 2015, doi: 10.1016/j.wace.2015.10.006.
- [101] M. V. K. Sivakumar e R. P. Motha, *Managing Weather and Climate Risks in Agriculture*. Springer, 2007. doi: 10.1007/978-3-540-72746-0.
- [102] P. R. M. Pontes, F. M. Fan, W. Collischonn, e R. C. D. Paiva, “Análise da sensibilidade da vazão do rio Paraná a potencial alteração da precipitação”, em *XX Simpósio Brasileiro de Recursos Hídricos*, Bento Gonçalves: Associação Brasileira de Recursos Hídricos, 2013, p. 1–8.
- [103] F. M. Fan, W. Collischonn, A. Meller, e L. C. M. Botelho, “Ensemble streamflow forecasting experiments in a tropical basin: The São Francisco river case study”, *J Hydrol (Amst)*, vol. 519, n° PD, p. 2906–2919, 2014, doi: 10.1016/j.jhydrol.2014.04.038.
- [104] T. L. Dias, M. Cataldi, e V. H. Ferreira, “Aplicação de técnicas de redes neurais e modelagem atmosférica para elaboração de previsões de vazão na Bacia do Rio Grande (MG)”, *Engenharia Sanitaria e Ambiental*, vol. 22, n° 1, p. 169–178, 2017, doi: 10.1590/S1413-41522016158015.
- [105] M. Ali, R. C. Deo, Y. Xiang, Y. Li, e Z. M. Yaseen, “Forecasting long-term precipitation for water resource management: a new multi-step data-intelligent modelling approach”, *Hydrological Sciences Journal*, vol. 65, n° 16, p. 2693–2708, 2020, doi: 10.1080/02626667.2020.1808219.
- [106] G. J. Carbone e K. Dow, “Water resource management and drought forecasts in South Carolina”, *J Am Water Resour Assoc*, vol. 41, n° 1, p. 145–155, 2005, doi: 10.1111/j.1752-1688.2005.tb03724.x.
- [107] L. Lipper *et al.*, “Climate-smart agriculture for food security”, *Nat Clim Chang*, vol. 4, n° 12, p. 1068–1072, 2014, doi: 10.1038/nclimate2437.
-

- 
- [108] K. T. Ingram, M. C. Roncoli, e P. H. Kirshen, “Opportunities and constraints for farmers of west Africa to use seasonal precipitation forecasts with Burkina Faso as a case study”, *Agric Syst*, vol. 74, n° 3, p. 331–349, 2002, doi: 10.1016/S0308-521X(02)00044-6.
- [109] M. I. Brunner, L. Slater, L. M. Tallaksen, e M. Clark, “Challenges in modeling and predicting floods and droughts: A review”, *Wiley Interdisciplinary Reviews: Water*, vol. 8, n° 3, p. 1–32, 2021, doi: 10.1002/wat2.1520.
- [110] Z. Toth e R. Buizza, “Weather Forecasting: What Sets the Forecast Skill Horizon?”, em *Sub-seasonal to Seasonal Prediction: The Gap Between Wather and Climate Forecast*, 1° ed, A. W. Robertson e F. Vitart, Orgs., Elsevier, 2019, p. 16–45. doi: 10.1016/C2016-0-01594-2.
- [111] J. W. M. Lima, W. Collischonn, e J. A. Marengo, *Efeito das Mudanças Climáticas na Geração de Energia Elétrica*, vol. 148. 2014.
- [112] Z. Liu e M. Alexander, “Atmospheric bridge, oceanic tunnel, and global climatic teleconnections”, *Reviews of Geophysics*, vol. 45, n° 2, p. 1–34, 2007, doi: 10.1029/2005RG000172.
- [113] M. S. Reboita *et al.*, “Impacts of teleconnection patterns on South America climate”, *Ann N Y Acad Sci*, p. 1–38, 2021, doi: 10.1111/nyas.14592.
- [114] P. Nobre e J. Shukla, “Variations of sea surface temperature, wind stress, and rainfall over the Tropical Atlantic and South America”, *J Clim*, vol. 9, n° 10, p. 2464–2479, 1996, doi: 10.1175/1520-0442(1996)009<2464:VOSSTW>2.0.CO;2.
- [115] L. Goddard, S. J. Mason, S. E. Zebiak, C. F. Ropelewski, R. Basher, e M. A. Cane, “Current approaches to seasonal-to-interannual climate predictions”, *International Journal of Climatology*, vol. 21, n° 9, p. 1111–1152, 2001, doi: 10.1002/joc.636.
- [116] L. P. Pezzi, V. Ubarana, e C. Repelli, “Desempenho e previsões de um modelo regional estatístico para a região sul do Brasil”, *Revista Brasileira de Geofísica*, vol. 18, n° 2, p. 128–144, 2000, doi: 10.1590/s0102-261x2000000200003.
- [117] C. K. Folland, A. W. Colman, D. P. Rowell, e M. K. Davey, “Predictability of northeast Brazil rainfall and real-time forecast skill, 1987-98”, *J Clim*, vol. 14, n° 9, p. 1937–1958, 2001, doi: 10.1175/1520-0442(2001)014<1937:PONBRA>2.0.CO;2.
- [118] G. T. Diro, E. Black, e D. I. F. Grimes, “Seasonal forecasting of Ethiopian spring rains”, *Meteorological Applications*, vol. 15, p. 73–83, 2008, doi: 10.1002/met.63.
- [119] Z. Zeng, W. W. Hsieh, A. Shabbar, e W. R. Burrows, “Seasonal prediction of winter extreme precipitation over Canada by support vector regression”, *Hydrol Earth Syst Sci*, vol. 15, n° 1, p. 65–74, 2011, doi: 10.5194/hess-15-65-2011.
- [120] S. Córdoba-Machado, R. Palomino-Lemus, S. R. Gámiz-Fortis, Y. Castro-Díez, e M. J. Esteban-Parra, “Influence of tropical Pacific SST on seasonal precipitation in Colombia: prediction using El Niño and El Niño Modoki”, *Clim Dyn*, vol. 44, n° 5–6, p. 1293–1310, 2015, doi: 10.1007/s00382-014-2232-3.
-

- 
- [121] B. Choubin, G. Zehtabian, A. Azareh, E. Rafiei-Sardooi, F. Sajedi-Hosseini, e Ö. Kişi, “Precipitation forecasting using classification and regression trees (CART) model: a comparative study of different approaches”, *Environ Earth Sci*, vol. 77, n° 8, 2018, doi: 10.1007/s12665-018-7498-z.
- [122] X. Quan, M. Hoerling, J. Whitaker, G. Bates, e T. Xu, “Diagnosing sources of U.S. seasonal forecast skill”, *J Clim*, vol. 19, n° 13, p. 3279–3293, 2006, doi: 10.1175/JCLI3789.1.
- [123] C. A. S. Coelho, D. B. Stephenson, M. Balmaseda, F. J. Doblas-Reyes, e G. J. Van Oldenborgh, “Toward an Integrated Seasonal Forecasting System for South America”, *J Clim*, vol. 19, p. 3704–3721, 2006, doi: 10.1175/JCLI3801.1.
- [124] H. S. Badr, B. F. Zaitchik, e S. D. Guikema, “Application of statistical models to the prediction of seasonal rainfall anomalies over the Sahel”, *J Appl Meteorol Climatol*, vol. 53, n° 3, p. 614–636, 2014, doi: 10.1175/JAMC-D-13-0181.1.
- [125] L. Gerlitz, S. Vorogushyn, H. Apel, A. Gafurov, K. Unger-Shayesteh, e B. Merz, “A statistically based seasonal precipitation forecast model with automatic predictor selection and its application to central and south Asia”, *Hydrol Earth Syst Sci*, vol. 20, n° 11, p. 4605–4623, 2016, doi: 10.5194/hess-20-4605-2016.
- [126] L. Xu, N. Chen, X. Zhang, e Z. Chen, “A data-driven multi-model ensemble for deterministic and probabilistic precipitation forecasting at seasonal scale”, *Clim Dyn*, vol. 54, n° 7–8, p. 3355–3374, 2020, doi: 10.1007/s00382-020-05173-x.
- [127] J. A. Anochi, V. A. de Almeida, e H. F. de C. Velho, “Machine learning for climate precipitation prediction modeling over South America”, *Remote Sens (Basel)*, vol. 13, p. 2468, 2021, doi: 10.3390/rs13132468.
- [128] P. B. Gibson, W. E. Chapman, A. Altinok, L. Delle Monache, M. J. DeFlorio, e D. E. Waliser, “Training machine learning models on climate model output yields skillful interpretable seasonal precipitation forecasts”, *Commun Earth Environ*, vol. 2, n° 1, p. 1–13, dez. 2021, doi: 10.1038/s43247-021-00225-4.
- [129] X. Wu *et al.*, “The development of a hybrid wavelet-arima-lstm model for precipitation amounts and drought analysis”, *Atmosphere (Basel)*, vol. 12, n° 1, 2021, doi: 10.3390/ATMOS12010074.
- [130] E. Pinheiro e T. B. M. J. Ouarda, “Short-lead seasonal precipitation forecast in northeastern Brazil using an ensemble of artificial neural networks”, *Sci Rep*, vol. 13, n° 1, dez. 2023, doi: 10.1038/s41598-023-47841-y.
- [131] W. G. Li, L. D. A. Sá, G. S. S. D. Prasad, A. G. Nowosad, M. J. A. Bolzan, e E. S. M. Chiang, “Neural network adaptive wavelets for predictions of the Northeastern Brazil monthly rainfall anomalies time series”, em *Applications and Science of Artificial Neural Networks II*, S. K. Rogers e D. W. Ruck, Orgs., Orlando, FL, United States, 1996, p. 175–187. doi: 10.1117/12.235908.
- [132] M. N. Ward e C. K. Folland, “Prediction of seasonal rainfall in the north Nordeste of Brazil using eigenvectors of sea-surface temperature”, *International Journal of Climatology*, vol. 11, n° 7, p. 711–743, 1991, doi: 10.1002/joc.3370110703.
-

- 
- [133] A. R. da Paz, C. B. Uvo, J. M. Bravo, W. Collischonn, e H. R. da Rocha, “Seasonal precipitation forecast based on artificial neural networks”, em *Computational Methods for Agricultural Research: Advances and Applications*, H. A. do Prado, A. J. B. Luiz, e H. C. Filho, Orgs., Hershey: IGI Global, 2010, p. 326–354. doi: 10.4018/978-1-61692-871-1.ch016.
- [134] J. A. Anochi e H. F. de C. Velho, “PREVISÃO CLIMÁTICA DE PRECIPITAÇÃO PARA A REGIÃO SUL POR REDE NEURAL AUTOCONFIGURADA”, *Ciência e Natura*, vol. 38, p. 98, jul. 2016, doi: 10.5902/2179460x19968.
- [135] C. Milléo e R. C. de Almeida, “Application of RBF artificial neural networks to precipitation and temperature forecasting in Paraná, Brazil”, *Ciência e Natura*, vol. 43, p. e40, mar. 2021, doi: 10.5902/2179460x43258.
- [136] V. S. Monego, J. A. Anochi, e H. F. de C. Velho, “South America Seasonal Precipitation Prediction by Gradient-Boosting Machine-Learning Approach”, *Atmosphere (Basel)*, vol. 13, n° 2, fev. 2022, doi: 10.3390/atmos13020243.
- [137] M. S. Reboita, M. A. Gan, R. P. da Rocha, e T. Ambrizzi, “Regimes de precipitação na América do Sul: uma revisão bibliográfica”, *Revista Brasileira de Meteorologia*, vol. 25, n° 2, p. 185–204, 2010, doi: 10.1590/s0102-77862010000200004.
- [138] M. F. L. de Quadro, L. H. R. Machado, S. Calbete, N. N. M. Batista, e G. S. de Oliveira, “Climatologia de precipitação e temperatura”, *Climanálise - Boletim de Monitoramento e Análise Climática*, n° especial comemorativa de 10 anos, 1996, [Online]. Disponível em: <http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/chuesp.html>
- [139] M. Chen *et al.*, “Assessing objective techniques for gauge-based analyses of global daily precipitation”, *Journal of Geophysical Research Atmospheres*, vol. 113, n° 4, p. 1–13, 2008, doi: 10.1029/2007JD009132.
- [140] Q. Sun, C. Miao, Q. Duan, H. Ashouri, S. Sorooshian, e K. L. Hsu, “A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons”, *Reviews of Geophysics*, vol. 56, n° 1, p. 79–107, 2018, doi: 10.1002/2017RG000574.
- [141] CPC, “Gauge-Based Analysis of Global Daily Precipitation”. [Online]. Disponível em: [https://ftp.cpc.ncep.noaa.gov/precip/CPC\\_UNI\\_PRCP/GAUGE\\_GLB/%3E](https://ftp.cpc.ncep.noaa.gov/precip/CPC_UNI_PRCP/GAUGE_GLB/%3E).
- [142] V. B. S. Silva, V. E. Kousky, e R. W. Higgins, “Daily precipitation statistics for South America: An intercomparison between NCEP reanalyses and observations”, *J Hydrometeorol*, vol. 12, n° 1, p. 101–117, 2011, doi: 10.1175/2010JHM1303.1.
- [143] L. M. V. Carvalho, C. Jones, A. N. D. Posadas, R. Quiroz, B. Bookhagen, e B. Liebmann, “Precipitation characteristics of the South American monsoon system derived from multiple datasets”, *J Clim*, vol. 25, n° 13, p. 4600–4620, 2012, doi: 10.1175/JCLI-D-11-00335.1.
- [144] V. A. de Almeida, E. Marton, e A. M. B. Nunes, “Assessing the ability of three global reanalysis products to reproduce South American monsoon precipitation”, *Atmósfera*, vol. 31, n° 1, p. 1–10, 2018, doi: 10.20937/ATM.2018.31.01.01.
- [145] ECMWF, “SEAS5 user guide”, 2017.
-

- 
- [146] S. J. Johnson *et al.*, “SEAS5: The new ECMWF seasonal forecast system”, *Geosci Model Dev*, vol. 12, n° 3, p. 1087–1117, 2019, doi: 10.5194/gmd-12-1087-2019.
- [147] T. Stockdale, S. Johnson, L. Ferranti, M. Balmaseda, e S. Briceag, “ECMWF ’s new long-range forecasting system SEAS5”, *ECMWF Newsletter*, n° 154, p. 15–20, 2018, doi: 10.21957/tsb6n1.
- [148] Copernicus, “Copernicus Climate Data Store”. [Online]. Disponível em: <https://cds.climate.copernicus.eu/cdsapp#!/home>
- [149] M. A. L. Sacco, “Teleconexões atmosféricas e a previsão numérica do clima na América do Sul”, Universidade de São Paulo, 2010.
- [150] C. A. de Souza e M. S. Reboita, “Ferramenta para o monitoramento dos padrões de teleconexão na América do Sul”, *Terrae Didactica*, vol. 17, p. e02109, 2021, doi: 10.20396/td.v17i00.8663474.
- [151] K. E. Trenberth, “The Definition of El Niño”, *Bull Am Meteorol Soc*, vol. 78, n° 12, p. 2771–2777, 1997, doi: 10.1175/1520-0477(1997)078<2771:TDOENO>2.0.CO;2.
- [152] K. E. Trenberth e D. P. Stepaniak, “Indices of El Niño evolution”, *J Clim*, vol. 14, n° 8, p. 1697–1701, 2001, doi: 10.1175/1520-0442(2001)014<1697:LIOENO>2.0.CO;2.
- [153] B. Huang *et al.*, “Extended reconstructed Sea surface temperature, Version 5 (ERSSTv5): Upgrades, validations, and intercomparisons”, *J Clim*, vol. 30, n° 20, p. 8179–8205, 2017, doi: 10.1175/JCLI-D-16-0836.1.
- [154] M. H. Glantz e I. J. Ramirez, “Reviewing the Oceanic Niño Index (ONI) to Enhance Societal Readiness for El Niño’s Impacts”, *International Journal of Disaster Risk Science*, vol. 11, n° 3, p. 394–403, 2020, doi: 10.1007/s13753-020-00275-w.
- [155] C. F. Ropelewski e P. D. Jones, “An Extension of the Tahiti–Darwin Southern Oscillation Index”, *Mon Weather Rev*, vol. 115, n° 9, p. 2161–2165, 1987, doi: 10.1175/1520-0493(1987)115<2161:AEOTTS>2.0.CO;2.
- [156] W. Shi, “Frequently Asked Questions Regarding CPC’s Current Monthly Atmospheric and SST Index Values”. Acessado: 14 de setembro de 2021. [Online]. Disponível em: <https://www.cpc.ncep.noaa.gov/data/indices/Readme.index.shtml#SOICALC>
- [157] K. Wolter, “The Southern Oscillation in surface circulation and climate over the tropical Atlantic, Eastern Pacific, and Indian Oceans as captured by cluster analysis”, *Journal of Climate and Applied Meteorology*, vol. 26, n° 4, p. 540–558, 1987, doi: 10.1175/1520-0450(1987)026<0540:TSOISC>2.0.CO;2.
- [158] K. Wolter e M. S. Timlin, “Monitoring ENSO in COADS with a Seasonally Adjusted Principal Component Index”, em *Proceedings of the 17th Climate Diagnostics Workshop*, Norman, OK: NOAA/NMC/CAC, NSSL, Oklahoma Climate Survey, CIMMS and the School of Meteorology, University of Oklahoma, 1993, p. 52–57.
- [159] PSL, “Multivariate ENSO Index Version 2 (MEI.v2)”. Acessado: 14 de setembro de 2021. [Online]. Disponível em: <https://psl.noaa.gov/enso/mei/>
-

- 
- [160] C. A. Smith e P. D. Sardeshmukh, “The effect of ENSO on the intraseasonal variance of surface temperatures in winter”, *International Journal of Climatology*, vol. 20, n° 13, p. 1543–1557, 2000, doi: 10.1002/1097-0088(20001115)20:13<1543::AID-JOC579>3.0.CO;2-A.
- [161] D. B. Enfield, A. M. Mestas-Nuñez, D. A. Mayer, e L. Cid-Serrano, “How ubiquitous is the dipole relationship in tropical Atlantic sea surface temperatures?”, *J Geophys Res Oceans*, vol. 104, n° C4, p. 7841–7848, 1999, doi: 10.1029/1998jc900109.
- [162] N. H. Saji e T. Yamagata, “Possible impacts of Indian Ocean Dipole mode events on global climate”, *Clim Res*, vol. 25, n° 2, p. 151–169, 2003, doi: 10.3354/cr025151.
- [163] N. H. Saji, B. N. Goswami, P. N. Vinayachandran, e T. Yamagata, “A dipole mode in the tropical Indian Ocean”, *Nature*, vol. 401, n° September, p. 360–364, 1999, doi: 10.1038/43854.
- [164] H. C. Nnamchi, J. Li, e R. N. C. Anyadike, “Does a dipole mode really exist in the South Atlantic Ocean?”, *Journal of Geophysical Research Atmospheres*, vol. 116, n° 15, p. 1–15, 2011, doi: 10.1029/2010JD015579.
- [165] Y. Morioka, T. Tozuka, e T. Yamagata, “On the growth and decay of the subtropical dipole mode in the South Atlantic”, *J Clim*, vol. 24, n° 21, p. 5538–5554, 2011, doi: 10.1175/2011JCLI4010.1.
- [166] K. C. Mo e R. W. Higgins, “The Pacific-South American modes and tropical convection during the Southern Hemisphere winter”, *Mon Weather Rev*, vol. 126, n° 6, p. 1581–1596, 1998, doi: 10.1175/1520-0493(1998)126<1581:TPSAMA>2.0.CO;2.
- [167] J. W. Kidson, “Principal modes of Southern Hemisphere low-frequency variability obtained from NCEP-NCAR reanalyses”, *J Clim*, vol. 12, n° 9, p. 2808–2830, 1999, doi: 10.1175/1520-0442(1999)012<2808:PMOSHL>2.0.CO;2.
- [168] K. C. Mo, “Relationships between low-frequency variability in the Southern Hemisphere and sea surface temperature anomalies”, *J Clim*, vol. 13, n° 20, p. 3599–3610, 2000, doi: 10.1175/1520-0442(2000)013<3599:RBLFVI>2.0.CO;2.
- [169] M. S. Reboita, R. P. da Rocha, T. Ambrizzi, e S. Sugahara, “South Atlantic Ocean cyclogenesis climatology simulated by regional climate model (RegCM3)”, *Clim Dyn*, vol. 35, n° 7, p. 1331–1347, 2010, doi: 10.1007/s00382-009-0668-7.
- [170] E. M. de Jesus, R. P. da Rocha, N. M. Crespo, M. S. Reboita, e L. F. Gozzo, “Multi-model climate projections of the main cyclogenesis hot-spots and associated winds over the eastern coast of South America”, *Clim Dyn*, vol. 56, n° 1–2, p. 537–557, 2021, doi: 10.1007/s00382-020-05490-1.
- [171] M. S. Reboita, T. Ambrizzi, B. A. Silva, R. F. Pinheiro, e R. P. da Rocha, “The South Atlantic Subtropical Anticyclone: Present and future climate”, *Front Earth Sci (Lausanne)*, vol. 7, n° February, p. 1–15, 2019, doi: 10.3389/feart.2019.00008.
- [172] R. R. Hocking, “A Biometrics Invited Paper. The Analysis and Selection of Variables in Linear Regression”, *Biometrics*, vol. 32, n° 1, p. 1–49, 1976, doi: 10.2307/2529336.
-

- 
- [173] M. Seibert, B. Merz, e H. Apel, “Seasonal forecasting of hydrological drought in the Limpopo Basin: A comparison of statistical methods”, *Hydrol Earth Syst Sci*, vol. 21, n° 3, p. 1611–1629, mar. 2017, doi: 10.5194/hess-21-1611-2017.
- [174] A. Jozaghi *et al.*, “Multi-model streamflow prediction using conditional bias-penalized multiple linear regression”, *Stochastic Environmental Research and Risk Assessment*, vol. 35, n° 11, p. 2355–2373, nov. 2021, doi: 10.1007/s00477-021-02048-3.
- [175] A. M. Moradi, A. B. Dariane, G. Yang, e P. Block, “Long-range reservoir inflow forecasts using large-scale climate predictors”, *International Journal of Climatology*, vol. 40, n° 13, 2020, doi: 10.1002/joc.6526.
- [176] Y. Gupta e A. Saraswat, “Machine learning techniques for short-term forecasting of wind power generation”, em *Advanced Machine Learning Technologies and Applications: Proceedings of AMLTA 2020*, A. E. Hassanien, R. Bhatnagar, e A. Darwish, Orgs., Springer, 2021, p. 439–448. doi: 10.1007/978-981-15-3383-9\_39.
- [177] S. J. Miller, “Chapter 24: The Method of Least Squares”, em *The Probability Lifesaver: All the Tools You Need to Understand Chance*, Princeton, New Jersey: Princeton University Press, 2017, p. 625–635. doi: 10.1515/9781400885381-026.
- [178] P. T. Pope e J. T. Webster, “The Use of an F-Statistic in Stepwise Regression Procedures”, *Technometrics*, vol. 14, n° 2, p. 327–340, 1972, doi: 10.1080/00401706.1972.10488919.
- [179] C. Cortes e V. Vapnik, “Support-Vector Networks”, *Machine Learning*, vol. 20, n° 3, p. 273–297, 1995, doi: 10.1007/BF00994018.
- [180] V. Vapnik, *The Nature of Statistical Learning Theory*, 2nd ed. Springer, 2000.
- [181] L. Yang, M. He, J. Zhang, e V. Vittal, “Support-vector-machine-enhanced Markov model for short-term wind power forecast”, *IEEE Trans Sustain Energy*, vol. 6, n° 3, p. 791–799, jul. 2015, doi: 10.1109/TSTE.2015.2406814.
- [182] Y. Wang, X. Zhou, L. Liang, M. Zhang, Q. Zhang, e Z. Niu, “Short-term wind speed forecast based on least squares support vector machine”, *Journal of Information Processing Systems*, vol. 14, n° 6, p. 1385–1397, 2018, doi: 10.3745/JIPS.04.0069.
- [183] K. Rasouli, W. W. Hsieh, e A. J. Cannon, “Daily streamflow forecasting by machine learning methods with weather and climate inputs”, *J Hydrol (Amst)*, vol. 414–415, 2012, doi: 10.1016/j.jhydrol.2011.10.039.
- [184] S. Bhandari, B. Thakur, A. Kalra, W. P. Miller, V. Lakshmi, e P. Pathak, “Streamflow forecasting using singular value decomposition and support vector machine for the upper Rio Grande river basin”, *J Am Water Resour Assoc*, vol. 55, n° 3, 2019, doi: 10.1111/1752-1688.12733.
- [185] J. Yan, J. Jin, F. Chen, G. Yu, H. Yin, e W. Wang, “Urban flash flood forecast using support vector machine and numerical simulation”, *Journal of Hydroinformatics*, vol. 20, n° 1, 2018, doi: 10.2166/hydro.2017.175.
-

- 
- [186] O. L. Mangasarian, *Nonlinear Programming*. Philadelphia: Society for Industrial and Applied Mathematic, 1994. doi: 10.1137/1.9781611971255.
- [187] A. J. Smola e B. Schölkopf, “A tutorial on support vector regression”, *Stat Comput*, vol. 14, nº 3, p. 199–222, 2004, doi: 10.1023/B:STCO.0000035301.49549.88.
- [188] J. D. Evans, *Straightforward Statistics for the Behavioral Sciences*. Pacific Grove, CA: Thomson Brooks/Cole Publishing Company, 1996.
- [189] D. C. Montgomery, C. L. Jennings, e M. Kulahci, *Introduction to Time Series Analysis and Forecasting*, 2º ed. New Jersey: John Wiley & Sons, 2008.
- [190] R. Pal, *Predictive Modeling of Drug Sensitivity*. 2017. doi: 10.1016/c2015-0-04656-1.
- [191] A. S. de Oliveira, “Interações entre Sistemas Frontais na América do Sul e Convecção na Amazônia”, Instituto Nacional de Pesquisas Espaciais, 1986.
- [192] S. Gubler *et al.*, “Assessment of ECMWF SEAS5 seasonal forecast performance over South America”, *Weather Forecast*, vol. 35, nº 2, p. 561–584, 2020, doi: 10.1175/WAF-D-19-0106.1.
- [193] M. P. Darji, V. K. Dabhi, e H. B. Prajapati, “Rainfall forecasting using neural network: A survey”, em *Conference Proceeding - 2015 International Conference on Advances in Computer Engineering and Applications, ICACEA 2015*, 2015, p. 706–713. doi: 10.1109/ICACEA.2015.7164782.
- [194] B. Choubin, S. Khalighi-Sigaroodi, A. Malekian, e Ö. Kişi, “Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals”, *Hydrological Sciences Journal*, vol. 61, nº 6, p. 1001–1009, 2016, doi: 10.1080/02626667.2014.966721.
- [195] L. Xu, N. Chen, X. Zhang, e Z. Chen, “An evaluation of statistical, NMME and hybrid models for drought prediction in China”, *J Hydrol (Amst)*, vol. 566, nº January, p. 235–249, 2018, doi: 10.1016/j.jhydrol.2018.09.020.
- [196] I. Petry *et al.*, “Seasonal streamflow forecasting in South America’s largest rivers”, *J Hydrol Reg Stud*, vol. 49, out. 2023, doi: 10.1016/j.ejrh.2023.101487.
- [197] E. A. Gerlein, M. McGinnity, A. Belatreche, e S. Coleman, “Evaluating machine learning classification for financial trading: An empirical approach”, *Expert Syst Appl*, vol. 54, p. 193–207, jul. 2016, doi: 10.1016/j.eswa.2016.01.018.
- [198] D. C. Yıldırım, I. H. Toroslu, e U. Fiore, “Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators”, *Financial Innovation*, vol. 7, nº 1, dez. 2021, doi: 10.1186/s40854-020-00220-2.
- [199] A. Ibrahim, R. Kashef, e L. Corrigan, “Predicting market movement direction for bitcoin: A comparison of time series modeling methods”, *Computers and Electrical Engineering*, vol. 89, p. 106905, jan. 2021, doi: 10.1016/j.compeleceng.2020.106905.
-

- 
- [200] F. Valencia, A. Gómez-Espinosa, e B. Valdés-Aguirre, “Price movement prediction of cryptocurrencies using sentiment analysis and machine learning”, *Entropy*, vol. 21, n° 6, jun. 2019, doi: 10.3390/e21060589.
- [201] I. E. Livieris, N. Kiriakidou, S. Stavroyiannis, e P. Pintelas, “An advanced CNN-LSTM model for cryptocurrency forecasting”, *Electronics (Switzerland)*, vol. 10, n° 3, p. 1–16, fev. 2021, doi: 10.3390/electronics10030287.
- [202] Y. Shynkevich, T. M. McGinnity, S. A. Coleman, A. Belatreche, e Y. Li, “Forecasting price movements using technical indicators: Investigating the impact of varying input window length”, *Neurocomputing*, vol. 264, p. 71–88, nov. 2017, doi: 10.1016/j.neucom.2016.11.095.
- [203] N. Perez-Mora, M. L. Alomar, e V. Martinez-Moll, “Spanish energy market: Overview towards price forecast”, *International Journal of Energy Economics and Policy*, vol. 8, n° 3, p. 1–7, 2018, [Online]. Disponível em: <http://www.econjournals.com>
- [204] C. McHugh, S. Coleman, e D. Kerr, “Technical indicators for energy market trading”, *Machine Learning with Applications*, vol. 6, p. 100182, dez. 2021, doi: 10.1016/j.mlwa.2021.100182.
- [205] B. M. Henrique, V. A. Sobreiro, e H. Kimura, “Literature review: Machine learning techniques applied to financial market prediction”, *Expert Syst Appl*, vol. 124, p. 226–251, jun. 2019, doi: 10.1016/j.eswa.2019.01.012.
- [206] M. M. Kumbure, C. Lohrmann, P. Luukka, e J. Porras, “Machine learning techniques and data for stock market forecasting: A literature review”, *Expert Systems with Applications*, vol. 197. Elsevier Ltd, 1° de julho de 2022. doi: 10.1016/j.eswa.2022.116659.
- [207] S. Puri e L. K. Shrivastav, “Neural network for volatile stock market prediction”, em *Proceedings of the 2019 6th International Conference on Computing for Sustainable Global Development, INDIACom 2019*, Institute of Electrical and Electronics Engineers Inc., mar. 2019, p. 184–189.
- [208] P. R. Patil, D. Parasar, e S. Charhate, “A Literature Review on Machine Learning Techniques and Strategies Applied to Stock Market Price Prediction”, 2021, p. 121–135. doi: 10.1007/978-981-16-3915-9\_10.
- [209] M. R. Santos *et al.*, “Machine Learning Approach for Trend Prediction to Improve Returns on Brazilian Energy Market”, em *Proceedings - 2022 IEEE Latin American Conference on Computational Intelligence, LA-CCI 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/LA-CCI54402.2022.9981846.
- [210] D. D. de Castilho Braz *et al.*, “Multi-source data ensemble for energy price trend forecasting”, *Eng Appl Artif Intell*, vol. 133, p. 108125, jul. 2024, doi: 10.1016/j.engappai.2024.108125.
- [211] MME, *Portaria Normativa Nº 50/GM/MME, de 27 de setembro de 2022*. Brasil: Ministério de Minas e Energia, 2022, p. 1–1.
-

- 
- [212] MME, *Portaria N° 690/GM/MME, de 29 de setembro de 2022*. Brasília, Brasil: Ministério de Minas e Energia, 2022, p. 1–2. [Online]. Disponível em: [www.gov.br/mme](http://www.gov.br/mme),
- [213] J. Zhang, S. Cui, Y. Xu, Q. Li, e T. Li, “A novel data-driven stock price trend prediction system”, *Expert Syst Appl*, vol. 97, p. 60–69, maio 2018, doi: 10.1016/j.eswa.2017.12.026.
- [214] O. Bustos e A. Pomares-Quimbaya, “Stock market movement forecast: A systematic review”, *Expert Systems with Applications*, vol. 156. Elsevier Ltd, p. 113464, 15 de outubro de 2020. doi: 10.1016/j.eswa.2020.113464.
- [215] Y. Peng, P. H. M. Albuquerque, H. Kimura, e C. A. P. B. Saavedra, “Feature selection and deep neural networks for stock price direction forecasting using technical analysis indicators”, *Machine Learning with Applications*, vol. 5, p. 100060, 2021, doi: 10.1016/j.mlwa.2021.100060.
- [216] L. B. S. Morais, G. Aquila, V. A. D. de Faria, L. M. M. Lima, J. W. M. Lima, e A. R. de Queiroz, “Short-term load forecasting using neural networks and global climate models: An application to a large-scale electrical power system”, *Appl Energy*, vol. 348, out. 2023, doi: 10.1016/j.apenergy.2023.121439.
- [217] G. Aquila, L. B. S. Morais, V. A. D. de Faria, J. W. M. Lima, L. M. M. Lima, e A. R. de Queiroz, “An Overview of Short-Term Load Forecasting for Electricity Systems Operational Planning: Machine Learning Methods and the Brazilian Experience”, *Energies*, vol. 16, n° 21. Multidisciplinary Digital Publishing Institute (MDPI), 1° de novembro de 2023. doi: 10.3390/en16217444.
- [218] F. L. R. Torres, L. M. M. Lima, M. S. Reboita, A. R. de Queiroz, e J. W. M. Lima, “Integrating Hydrological and Machine Learning Models for Enhanced Streamflow Forecasting via Bayesian Model Averaging in a Hydro-Dominant Power System”, *Water (Basel)*, vol. 16, n° 4, p. 586, fev. 2024, doi: 10.3390/w16040586.
- [219] P. Piotrowski, D. Baczyński, M. Kopyt, e T. Gulczyński, “Advanced Ensemble Methods Using Machine Learning and Deep Learning for One-Day-Ahead Forecasts of Electric Energy Production in Wind Farms”, *Energies (Basel)*, vol. 15, n° 4, fev. 2022, doi: 10.3390/en15041252.
- [220] J. Maldonado-Correa, M. Valdiviezo-Condolo, M. S. Viñan-Ludeña, C. Samaniego-Ojeda, e M. Rojas-Moncayo, “Wind power forecasting for the Villonaco wind farm”, *Wind Engineering*, vol. 45, n° 5, p. 1145–1159, out. 2021, doi: 10.1177/0309524X20968817.
- [221] M. Elsaraiti e A. Merabet, “Solar Power Forecasting Using Deep Learning Techniques”, *IEEE Access*, vol. 10, p. 31692–31698, 2022, doi: 10.1109/ACCESS.2022.3160484.
- [222] S. Hochreiter e J. Schmidhuber, “Long Short-Term Memory”, *Neural Comput*, vol. 9, n° 8, p. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [223] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities.”, *Proc Natl Acad Sci U S A*, vol. 79, n° 8, 1982, doi: 10.1073/pnas.79.8.2554.
-

- 
- [224] M. Roodschild, J. Gotay Sardiñas, e A. Will, “A new approach for the vanishing gradient problem on sigmoid activation”, *Progress in Artificial Intelligence*, vol. 9, n° 4, 2020, doi: 10.1007/s13748-020-00218-y.
- [225] S. Hochreiter, “The vanishing gradient problem during learning recurrent neural nets and problem solutions”, *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, vol. 6, n° 2, 1998, doi: 10.1142/S0218488598000094.
- [226] W. Khan, S. Walker, e W. Zeiler, “Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach”, *Energy*, vol. 240, fev. 2022, doi: 10.1016/j.energy.2021.122812.
- [227] Y. Liu *et al.*, “Wind power short-term prediction based on LSTM and discrete wavelet transform”, *Applied Sciences (Switzerland)*, vol. 9, n° 6, 2019, doi: 10.3390/app9061108.
- [228] H. Palangi *et al.*, “Deep Sentence embedding using long short-term memory networks: Analysis and application to information retrieval”, *IEEE/ACM Trans Audio Speech Lang Process*, vol. 24, n° 4, 2016, doi: 10.1109/TASLP.2016.2520371.
- [229] B. McCann, J. Bradbury, C. Xiong, e R. Socher, “Learned in translation: Contextualized word vectors”, em *Advances in Neural Information Processing Systems*, 2017.
- [230] K. Cho *et al.*, “Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation”, em *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, A. Moschitti, B. Pang, e W. Daelemans, Orgs., Doha, Qatar: Association for Computational Linguistics, out. 2014, p. 1724–1734. doi: 10.3115/v1/D14-1179.
- [231] S. Gao *et al.*, “Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation”, *J Hydrol (Amst)*, vol. 589, out. 2020, doi: 10.1016/j.jhydrol.2020.125188.
- [232] B. Gao, X. Huang, J. Shi, Y. Tai, e R. Xiao, “Predicting day-ahead solar irradiance through gated recurrent unit using weather forecasting data”, *Journal of Renewable and Sustainable Energy*, vol. 11, n° 4, jul. 2019, doi: 10.1063/1.5110223.
- [233] M. Schuster e K. K. Paliwal, “Bidirectional recurrent neural networks”, *IEEE Transactions on Signal Processing*, vol. 45, n° 11, 1997, doi: 10.1109/78.650093.
- [234] T. Hastie, R. Tibshirani, e J. Friedman, *The Elements of Statistical Learning Data Mining, Inference, and Prediction*, 2° ed. New York/Berlin/Heidelberg: Springer, 2008.
- [235] C. J. Willmott, “On the validation of models”, *Phys Geogr*, vol. 2, p. 184–194, 1981, doi: 10.1080/02723646.1981.10642213.
- [236] D. E. Hinkle, W. Wiersma, e S. G. Jurs, *Applied Statistics for the Behavioral Sciences*, 5° ed. Boston: Houghton Mifflin, 2003.
- [237] CCEE, “Contratos CCEE”. Acessado: 22 de janeiro de 2024. [Online]. Disponível em: <https://www.ccee.org.br/mercado/contratos>
- [238] CCEE, “Regras de Comercialização: Contratos (versão 2024.1.0)”, São Paulo, 2024.
-

- 
- [239] ONS, “Procedimentos de Rede: Submódulo 2.4 - Critérios para estudos energéticos e hidrológicos”, Rio de Janeiro, 2022.
-