

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO DE ENGENHARIA DE PRODUÇÃO ELÉTRICA

Mattia Silva Valsangiacomo

**Análise Comparativa entre Rede Neural e Modelos Matemáticos na Previsão
do Preço de Liquidação das Diferenças de Energia no Brasil**

Florianópolis
2023

Mattia Silva Valsangiacomo

**Análise Comparativa entre Rede Neural e Modelos Matemáticos na Previsão
do Preço de Liquidação das Diferenças de Energia no Brasil**

Trabalho de Conclusão submetida ao Curso de Engenharia de Produção Elétrica da Universidade Federal de Santa Catarina para a obtenção do título de Engenheiro Eletricista com habilitação em Engenharia de Produção.

Orientador: Prof. Dr. Lynceo Falavigna Braghirolli

Florianópolis

2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Silva Valsangiacomo, Mattia

Análise comparativa entre rede neural e modelos matemáticos na previsão do preço de liquidação das diferenças de energia no Brasil / Mattia Silva Valsangiacomo ; orientador, Lynceo Falavigna Braghirolli, 2023.

63 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia de Produção Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia de Produção Elétrica. 2. PLD. 3. Rede Neural. 4. Modelos matemáticos. I. Falavigna Braghirolli, Lynceo. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Produção Elétrica. III. Título.

Mattia Silva Valsangiacomo

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de Engenheiro Eletricista com habilitação em Engenharia de Produção e aprovado em sua forma final pelo Curso de Engenharia de Produção Elétrica

Florianópolis, 30 de novembro de 2023



Coordenação do Curso

Banca Examinadora



Prof.(a) Lynceo Falavigna Braghirolli.
Instituição Universidade Federal de Santa Catarina



Prof.(a) Sérgio Fernando Mayerle.
Instituição Universidade Federal de Santa Catarina



Prof.(a) Javier Gutierrez Castro.
Instituição Universidade Federal de Santa Catarina

Florianópolis, 2023.

Quero expressar minha profunda gratidão aos meus pais, Daniele e Doris, por todo o apoio e encorajamento que me deram durante a realização deste trabalho. Vocês foram essenciais em cada etapa desta jornada, sempre oferecendo palavras e gestos que me motivaram a seguir em frente.

Ao meu orientador Lynceo, meu sincero agradecimento pela orientação valiosa, paciência e sabedoria compartilhada, que foram fundamentais para o desenvolvimento e conclusão deste projeto.

Agradeço também aos meus colegas e amigos, que estiveram ao meu lado, compartilhando conhecimentos e momentos de descontração que tornaram o processo mais agradável.

*“Our greatest weakness lies in giving up. The most certain way to succeed is always to try just one more
time.”*
(Thomas Edison)

RESUMO

Este trabalho tem como objetivo avaliar a diferentes modelos matemáticos e computacionais de séries temporais na previsão do Preço da Liquidação das Diferenças de energia (PLD) no Brasil. Para isso, foram revisados diversos artigos científicos e documentos governamentais relevantes, a fim de entender conceitos e estruturação do mercado de energia elétrica brasileiro, modelos matemáticos, modelos de *machine learning*, métricas de avaliação, além de identificar os critérios que influenciam no preço do PLD. Em seguida, foi realizada a coleta e limpeza dos dados necessários para o processo de previsão. Com isso este trabalho apresenta uma comparação entre modelos tradicionais de previsão de séries temporais (Holt-Winters e SARIMA) com um modelo de rede neural (LSTM). Os modelos foram projetados e avaliados de acordo com 4 métricas de erro (MAE, MSE, RMSE e MAPE). O modelo que apresentou o melhor resultado foi o SARIMA, com um MAE de 5,796, MSE de 272,737, RMSE de 16,514 e uma MAPE de 1,151%. Além disso, foi possível observar que tanto o Holt-Winters quanto o LSTM também obtiveram resultados satisfatórios

Palavras-chave: PLD. Modelos matemáticos. Rede Neural.

ABSTRACT

This study aimed to evaluate different mathematical and computational models of time series in forecasting the Settlement Price of Differences (PLD) of energy in Brazil. To do this, several scientific articles and relevant government documents were reviewed in order to understand concepts and the structuring of the Brazilian electric energy market, mathematical models, machine learning models, evaluation metrics, as well as to identify the criteria that influence the PLD price. Subsequently, the necessary data was collected and cleaned for the forecasting process. Thus, this work presents a comparison between traditional forecasting models of time series (Holt-Winters and SARIMA) with a neural network model (LSTM). The models were designed and evaluated according to 4 error metrics (MAE, MSE, RMSE, and MAPE). The model that showed the best result was the SARIMA, with an MAE of 5.7962, MSE of 272.737, RMSE of 16.5147, and a MAPE of 1.15%. In addition, it was possible to observe that both Holt-Winters and LSTM also obtained satisfactory results.

Keywords: PLD. Mathematical models. Neural Network.

LISTA DE FIGURAS

Figura 1 – Mapeamento organizacional dos agentes do setor elétrico brasileiro. . .	18
Figura 2 – Mapa do Sistema Interligado Nacional em 2022	20
Figura 3 – Mapa de Expansão do Sistema Interligado Nacional Horizonte 2024 . .	21
Figura 4 – Diferenças entre o consumidor livre e o especial	22
Figura 5 – Diferenças entre o ambiente livre e o regulado	23
Figura 6 – A forma geral de uma RNN	31
Figura 7 – Estrutura da rede LSTM	32
Figura 8 – Etapas metodológicas	36
Figura 9 – Variação do PLD 2022 e 2023	39
Figura 10 – Matriz dos valores históricos do PLD	40
Figura 11 – Média Aritmética do PLD	40
Figura 12 – Unificação dos <i>dataframes</i>	41
Figura 13 – Média do PLD Brasil - 2020 e 2021	41
Figura 14 – Média do CMO Brasil - 2020 e 2021	41
Figura 15 – Média geração Usina termelétrica - 2020 e 2021	42
Figura 16 – Código holt-winters com rolamento	43
Figura 17 – Previsão Holt-Winters com rolamento	44
Figura 18 – Previsão Holt-Winters com rolamento de 10/06/2021 a 11/06/2021 . .	44
Figura 19 – Previsão Holt-Winters com rolamento de 26/06/2021 a 29/06/2021 . .	45
Figura 20 – Previsão Holt-Winters com rolamento de 03/08/2021 a 09/08/2021 . .	45
Figura 21 – Código SARIMA com rolamento	46
Figura 22 – Combinações de parâmetros via Auto-ARIMA	47
Figura 23 – Previsão SARIMA com rolamento	48
Figura 24 – Previsão SARIMA com rolamento de 10/06/2021 a 13/06/2021	48
Figura 25 – Previsão SARIMA com rolamento de 25/06/2021 a 26/06/2021	49
Figura 26 – Código LSTM com rolamento	52
Figura 27 – Previsão LSTM com rolamento	53
Figura 28 – Previsão LSTM com rolamento de 11/06/2021 a 14/06/2021	53
Figura 29 – Previsão LSTM com rolamento de 25/06/2021 a 27/06/2021	54

LISTA DE TABELAS

Tabela 1 – Comparação das variáveis de entrada dos autores	25
Tabela 2 – Equações dos Modelos de Holt-Winters	28
Tabela 3 – Métricas de erro para o modelo Holt-Winters	46
Tabela 4 – Melhores parâmetros para o modelo SARIMA	48
Tabela 5 – Métricas de erro para o modelo Holt-Winters	49
Tabela 6 – Comparação das métricas de erro para os três modelos de SARIMA com rolamento	50
Tabela 7 – Resultados do Treinamento para Diferentes Combinações de Variáveis .	51
Tabela 8 – Parâmetros e Valores Utilizados no Modelo LSTM	51
Tabela 9 – Métricas de erro para o modelo LSTM	52
Tabela 10 – Comparação do modelos	54
Tabela 11 – Comparação do tempo de processamento do modelos	55

LISTA DE ABREVIATURAS E SIGLAS

ACR	Ambiente de Contratação Regulada
ACL	Ambiente de Contratação Livre
AIC	Akaike Information Criterion
ANEEL	Agência Nacional de Energia Elétrica
ARIMA	Auto Regressive Integrated Moving Averages
ABRACEEL	Associação Brasileira de Comercializadores de Energia
ASMAE	Administradora de Serviços do Mercado Atacadista de Energia
CCEE	Câmara de Comercialização de Energia Elétrica
CMO	Custo Marginal de Operação
CMSE	Comitê de Monitoramento do Setor Elétrico
CNPE	Conselho Nacional de Política de Energia
EPE	Empresa de Pesquisa Energética
HW	Holt-Winters
IDE	Ambiente de Desenvolvimento Integrado
KW	Kilowatt
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MCP	Mercado de Curto Prazo
MME	Ministério de Minas e Energia
MSE	Mean Square Error
ONS	Operador Nacional do Sistema Elétrico
PDO	Programação Diária de Energia
PLD	Preço de Liquidação das Diferenças
RNA	Rede Neural Artificial
RNN	Recurrent Neural Networks

RMSE	Root Mean Square Error
SARIMA	Seasonal Autoregressive Integrated Moving Average
SARIMAX	Seasonal Autoregressive Integrated Moving Average with Exogenous Regressors
SIN	Sistema Interligado Nacional
MAPE	Weighted Mean Absolute Percentage Error

SUMÁRIO

1	INTRODUÇÃO	14
1.1	PROBLEMATIZAÇÃO DO TEMA	14
1.2	OBJETIVOS	15
1.2.1	Objetivos Gerais	15
1.2.2	Objetivos Específicos	15
1.3	JUSTIFICATIVA	15
1.4	DELIMITAÇÃO	16
1.5	ESTRUTURA DO TRABALHO	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	MERCADO DE ENERGIA ELÉTRICA NO BRASIL	18
2.1.1	Agentes setoriais	18
2.1.2	Sistema interligado nacional	20
2.1.3	Ambientes de contratação	21
2.1.4	Mercado de Curto Prazo de Energia	23
2.1.5	Custo Marginal de Operação	24
2.1.6	Preço da Liquidação das Diferenças	24
2.1.7	Modelos de otimização e formação de preços	25
2.2	HOLT-WINTERS	26
2.3	SARIMA	28
2.4	REDES NEURAIS	30
2.4.1	LSTM	31
2.5	MÉTRICAS DE ERRO	33
2.5.1	MAPE	33
2.5.2	MAE	33
2.5.3	MSE	33
2.5.4	RMSE	34
3	METODOLOGIA	35
3.1	CLASSIFICAÇÃO DA PESQUISA	35
3.2	ETAPAS METODOLÓGICAS	35
3.2.1	Etapa 1: Revisão Bibliográfica	37
3.2.2	Etapa 2: Coleta de dados	37
3.2.3	Etapa 3: Adequação dos dados	37
3.2.4	Etapa 4: Seleção das variáveis do modelo LSTM	37
3.2.5	Etapa 5: Aplicação dos modelos selecionados	38
3.2.6	Etapa 6: Avaliação dos modelos de previsão	38
4	RESULTADOS E DISCUSSÕES	39
4.1	COLETA E LIMPEZA DOS DADOS	39

4.2	APLICAÇÃO DOS MODELOS SELECIONADOS	42
4.2.1	Modelo de Holt-Winters	42
4.2.2	SARIMA	46
4.2.3	LSTM	50
4.3	DISCUSSÃO DOS RESULTADOS	54
5	CONCLUSÃO	57
	REFERÊNCIAS	59

1 INTRODUÇÃO

No início dos anos 90, o setor elétrico brasileiro estava em uma situação muito delicada e o estado alegava que não tinha condições de investir. A inadimplência e calote institucionalizado demonstravam a dimensão da crise no setor e o enfraquecimento do modelo público e apontavam que a privatização se apresentava como uma das soluções (GOMES; VIEIRA, 2009).

A partir de 1995 com a Lei nº 9.074, começa, de fato, a construção de um ambiente regulatório que começou a modelar o mercado de energia elétrica no Brasil. Este marco regulatório permitiu aos consumidores a contratação de energia diretamente com os geradores, acabando com o modelo tradicional tarifário e iniciando o mercado livre de energia.

O mercado livre de energia ou ambiente de contratação livre (ACL) é o mercado em que os consumidores de energia elétrica negociam livremente as condições de fornecimento, preço, volume, a fonte da energia com algum agente (gerador ou comercializador). Os contratos firmados no ACL, são sancionados através da Câmara de Comercialização de Energia Elétrica (CCEE), em que essa também é responsável por calcular o Preço da Liquidação das Diferenças (PLD) do mercado de curto prazo (UFG, s.d.).

O Preço de Liquidação das Diferenças (PLD) é o valor de energia utilizado para liquidar as diferenças entre a energia gerada, consumida e a contratada. Em 1º de janeiro de 2021 uma nova mudança ocorreu: o PLD que antes era semanal passou a ser horário. O seu valor é calculado diariamente através de modelos computacionais para cada hora do dia seguinte (D+1), considerando diversos fatores como: condições climáticas, demanda, vazão das usinas hidrelétricas, entre outros (CCEE, s.d.[b]). É importante destacar que, apesar do PLD ser calculado diariamente para cada hora do dia seguinte, seus valores não são disponibilizados até que a data esteja vigente.

De acordo com COMERC (s.d.), a discretização horária permitiu uma precificação mais condizente da realidade operativa do sistema elétrico brasileiro. Também tornou possível uma melhor gestão da demanda tanto para os geradores quanto para os consumidores, em que estes podem otimizar suas operações, reduzindo os custos. Por fim, isso possibilitou o surgimento de novos negócios, a criação de novos produtos e serviços no mercado .

1.1 PROBLEMATIZAÇÃO DO TEMA

A matriz energética brasileira tem bastante versatilidade devido as hidrelétricas, que possibilitam a modulação da energia de uma maneira mais fácil. Enquanto a participação de hidrelétricas no sistema de geração brasileiro for a principal fonte, a variação do PLD não será tão grande. Porém, com o aumento da utilização de novas fontes, a variação do preço ao longo do dia se tornará maior, dificultando a previsão de preços futuros pelos

agentes de mercado.

A volatilidade do PLD é uma das maiores preocupações dos agentes do setor elétrico brasileiro, principalmente daqueles presentes no mercado livre. Os participantes do setor possuem diferentes estratégias de compra e venda da energia, para a maximização do seu lucro. Uma variação atípica do PLD pode ter um grande impacto financeiro e consequentemente afetando diferentes setores da economia.

Diante deste tipo de situação, busca-se prever os valores do PLD no mercado de curto prazo, a fim de mitigar as dúvidas dos agentes do setor elétrico e os riscos no processo de elaboração de estratégias de comercialização de energia. Como Lagasse (2020a) cita, modelos alternativos para o cálculo do PLD são convenientes para ajudar nas tomadas de decisão por parte dos geradores, compradores e comercializadores. Preferencialmente quando são utilizados dados facilmente adquiridos (fontes públicas) e que não exijam grande capacidade de processamento.

1.2 OBJETIVOS

A seguir estão descritos o objetivo geral e os objetivos específicos deste trabalho, no qual o primeiro tópico apresenta o objetivo de forma geral e o segundo trata das perspectivas específicas que contribuem para o objetivo geral.

1.2.1 Objetivos Gerais

O presente estudo tem como objetivo avaliar a acurácia de diferentes modelos de séries temporais na previsão do Preço da Liquidação das Diferenças de energia.

1.2.2 Objetivos Específicos

- a. Identificar as variáveis que influenciam o PLD com base na literatura;
- b. Verificar a influência do custo marginal de operação e da geração em usinas térmicas na formação do PLD;
- c. Desenvolver uma aplicação dos modelos Holt-Winters, SARIMA e LSTM para a previsão do PLD no mercado de energia elétrica brasileiro;
- d. Avaliar os erros de previsões dos modelos desenvolvidos.

1.3 JUSTIFICATIVA

O ambiente de contratação livre (ACL) do setor elétrico brasileiro tem sido uma fonte de economia para os consumidores, permitindo uma gestão de recursos mais eficiente. Nos últimos 20 anos, o ACL proporcionou uma redução acumulada de gastos de R\$ 339 bilhões, com o ano de 2022 alcançando o valor de R\$ 41 bilhões. Essa economia é reflexo

de diversos fatores operacionais e estratégicos que caracterizam o funcionamento desse mercado. Dentre esses o Preço de Liquidação das Diferenças (PLD) é o elemento chave, uma vez que ele atua como um preço de referência essencial.

A previsão horária é uma ferramenta valiosa por facilitar a alocação correta de recursos e por otimizar as operações no sistema elétrico. De acordo com o ONS (s.d.[c]), as previsões horárias são essenciais para o planejamento da operação e da programação do despacho de usinas, garantindo que a demanda seja atendida de maneira eficiente e confiável.

Já para os setor privado, as previsões horárias do PLD ajudam a criar projeções mais precisas do PLD, o que proporciona às empresas uma maior estabilidade para a análise de riscos e a definição de estratégias de compra e venda de energia, otimizando suas operações. Além disso uma previsão horária precisa do PLD pode ajudar a mitigar o risco de preços voláteis no mercado de curto prazo.

Por exemplo, considerando uma situação hipotética em que uma fábrica consome grandes quantidades de energia elétrica diariamente. Se essa empresa possuir um método preciso de previsão do PLD horário para o dia seguinte, a área de gestão energética poderá atuar de maneira mais eficiente. Ela pode identificar as horas do dia em que o preço da energia será mais baixo e ajustar sua produção para consumir mais energia nesses horários. Da mesma forma, durante os horários de pico de preço, a empresa pode reduzir sua demanda, utilizando fontes alternativas de energia ou pausando certas operações que não são críticas.

Utilizar os valores do Custo Marginal (CMO) de Operação e da geração de energia em termelétricas na previsão do PLD ajuda o modelo a possuir um resultado mais acurado. O CMO é uma variável fundamental porque reflete as condições de oferta e demanda no mercado elétrico, sendo uma das principais variáveis na determinação do PLD. Além disso, a geração de energia em termelétricas é crucial, uma vez que estas usinas, geralmente, são acionadas em situações de escassez de recursos hídricos ou do aumento na demanda energética, influenciando diretamente o custo marginal e consequentemente do próprio PLD.

1.4 DELIMITAÇÃO

Este trabalho se propõe a prever, através de modelos de previsão, apenas o Preço de liquidação diária de um dia a frente (D+1). A respeito das variáveis de entrada, foram selecionadas apenas aquelas que possuem discretização horária. Os modelos implementados (Holt-Winters, SARIMA e LSTM) foram escolhidos por serem clássicos de previsões de séries temporais. Ainda sobre o *forecasting* do PLD, o seguinte estudo utilizou de banco de dados provenientes apenas de fontes públicas e com valores existentes deste de 1º de julho de 2020 até 31º de agosto de 2021, período este em que o PLD teve diversas flutuações. Por fim, é válido ressaltar que o comprimento do período analisado para a previsão do

PLD horário foi escolhido com base na limitação de processamento computacional do autor.

1.5 ESTRUTURA DO TRABALHO

O Capítulo 1 desse trabalho apresenta inicialmente uma introdução dos assuntos por ele abordados. A partir da descrição do setor elétrico brasileiro é apresentado a problemática do estudo em questão. Na sequência é apresentado os objetivos e a justificativa desse trabalho, terminando com suas delimitações e estrutura.

O segundo capítulo apresenta a revisão bibliográfica que é utilizada para situar os leitores quanto aos assuntos que foram abordados na pesquisa. A fim de apresentar um embasamento teórico consistente, o capítulo é dividido em três subcapítulos, sendo o primeiro sobre o mercado de energia elétrica no Brasil, o segundo sobre modelos de previsão e o último sobre as métricas de erros.

Já o terceiro capítulo é composto tanto pela classificação da pesquisa, quanto pelas etapas metodológicas do trabalho, seguido pela descrição de suas etapas.

O Capítulo 4 dedica-se aos resultados e discussão dos 3 modelos de previsão utilizados, assim como a comparação destes com o de outros trabalhos que abordam o mesmo tema, previsão do PLD.

O último capítulo é constituído da conclusão e reflexão obtidas com o presente trabalho e sugestões de pesquisas futuras.

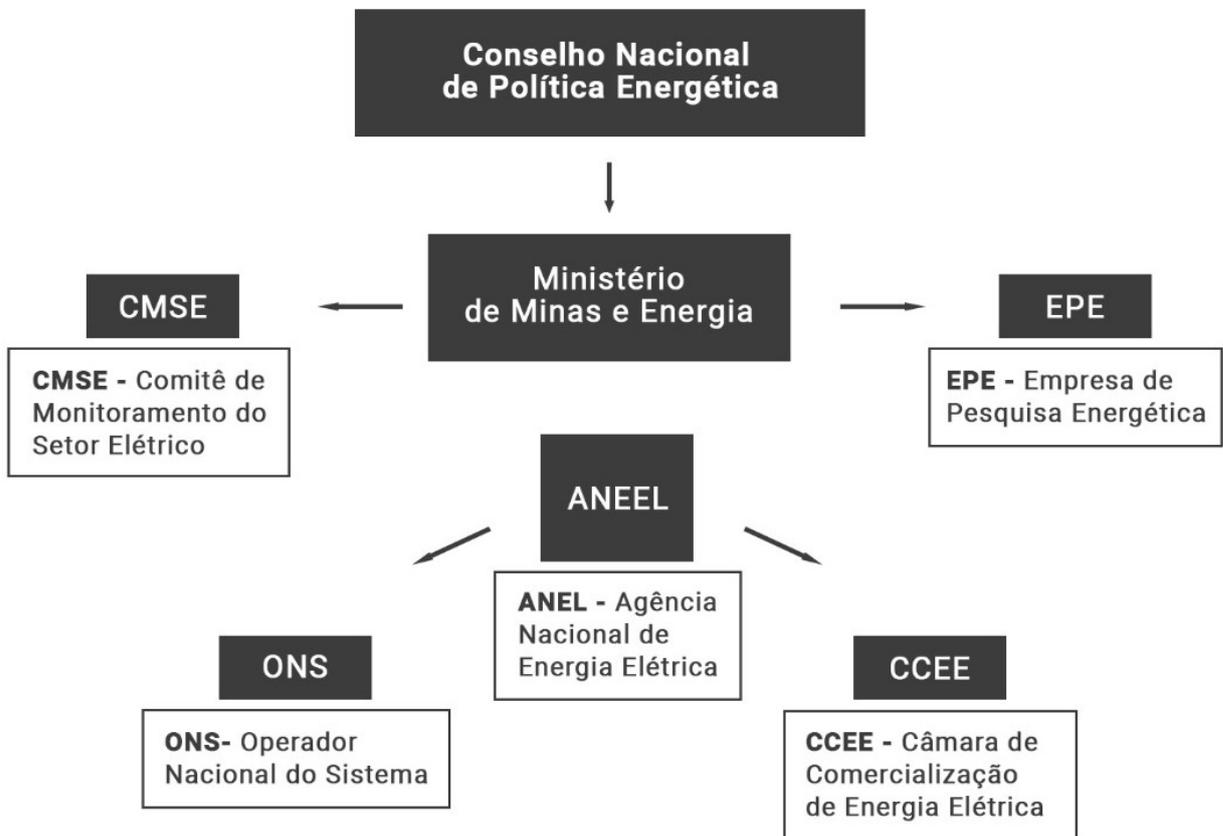
2 FUNDAMENTAÇÃO TEÓRICA

2.1 MERCADO DE ENERGIA ELÉTRICA NO BRASIL

2.1.1 Agentes setoriais

Antes de entrar mais a fundo sobre o Preço da Liquidação das Diferenças (PLD), primeiro é preciso ter uma visão mais macro do setor em que ele influencia. Por conta disso é importante entender a estruturação dos agentes que compõe este setor. Dessa forma, será descrito de maneira concisa as principais instituições, assim como seus papéis no setor em que estes estão atuando. Na Figura 1 tem-se a relação dos agentes a serem descritos.

Figura 1 – Mapeamento organizacional dos agentes do setor elétrico brasileiro.



Fonte: Próprio autor a partir de (CCEE, s.d.[a])

- CNPE

O Conselho Nacional de Política de Energia (CNPE), foi criado em 6 de agosto de 1997 pela Lei nº 9.478, com o intuito de ser o órgão responsável por assessorar o Presidente da República quanto a elaboração de diretrizes e políticas destinadas ao aproveitamento racional dos recursos energéticos brasileiros, assegurando o suprimento de insumos energéticos a todas às áreas do Brasil (BRASIL, 1997).

- MME

O Ministério de Minas e Energia (MME) do Brasil, foi criado em 22 de julho de 1960, pela lei nº 3.782 para auxiliar o governo em assuntos relacionados à exploração de recursos minerais e energéticos. No setor elétrico ele é responsável pela condução das políticas energéticas do país, ou seja, sua principal função é a formulação e implementação das políticas do setor, segundo as diretrizes do CNPE (FEDERAL, s.d.[b]).

- CMSE

O Comitê de Monitoramento do Setor Elétrico (CMSE) foi criado em 2004, pela lei 10.848, com o intuito de acompanhar e avaliar permanentemente a continuidade e a segurança do suprimento elétrico em todo o território brasileiro. Dentre todas as suas atividades, vale ressaltar que ela é responsável por acompanhar o desenvolvimento das atividades de geração, transmissão, distribuição, comercialização, importação e exportação de energia elétrica, gás natural e petróleo e seus derivados (FEDERAL, s.d.[a]).

- EPE

Criado em 15 de Março de 2004, segundo a Lei 10.847, a Empresa de Pesquisa Energética (EPE) tem como principal objetivo retomar a responsabilidade no Estado em garantir o desenvolvimento sustentável da infraestrutura energética do país. Além disso, a EPE tem como propósito, fornecer serviços ao Ministério de Minas e Energia, no segmento de pesquisas e estudos destinados ao auxílio do setor energético brasileiro (EPE, s.d.).

- ANEEL

Instituída por meio da Lei nº 9.427/96 e do Decreto nº 2.335/1997 e vinculada ao Ministério de Minas e Energia, a Agência Nacional de Energia Elétrica (ANEEL) foi criada com o propósito de regular o setor elétrico nacional, desde sua geração, passando pela transmissão, distribuição, até a comercialização. Em suas principais atividades, tem-se a elaboração de tarifas, Implementação de diretrizes e políticas relacionadas a exploração da energia elétrica, concessão de empreendimentos e serviços de energia elétrica e por fim, reduzir os conflitos administrativos, entre os agentes e entre esses agentes e os consumidores (ANEEL, s.d.).

- ONS

Criado como uma associação civil sem fins lucrativos em 26 de agosto de 1998, pela Lei nº 9.648, O Operador Nacional do Sistema Elétrico (ONS) tem como responsabilidade o controle e coordenação da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN) e pelo planejamento da operação dos sistemas isolados do país, tudo isso sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (ONS, s.d.[c]).

- CCEE

Criada em 1999, inicialmente com o nome de Administradora de Serviços do Mercado Atacadista de Energia (ASMAE), a Câmara de Comercialização de Energia Elétrica (CCEE) é uma associação civil sem fins lucrativos, que tem como foco viabilizar as atividades de compra e venda de energia em todo o território nacional, além de promover leilões, por delegação ANEEL, de compra e venda de energia elétrica. Por fim é a CCEE à responsável por levantar o Preço da Liquidação das Diferenças (PLD) do mercado de curto prazo no Brasil (UFG, s.d.).

2.1.2 Sistema interligado nacional

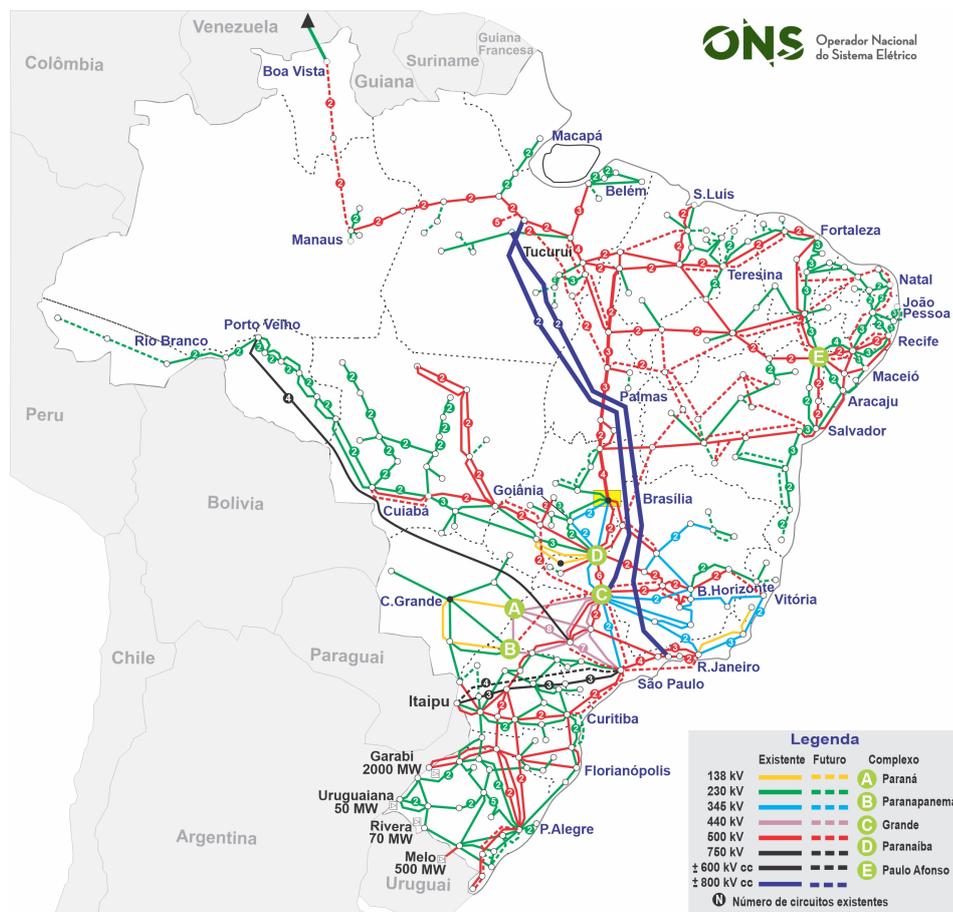
O Sistema Interligado Nacional (SIN) é um sistema hidro-termo-eólico de produção, transmissão e distribuição de energia elétrica, cuja operação está sob a coordenação e controle do Operador Nacional do Sistema Elétrico (ONS). Atualmente o SIN é dividido em 4 regiões, sendo eles: Sul, Sudeste/Centro-Oeste, Nordeste e grande parte da região Norte. A conexão entre esses subgrupos é feita por meio de malhas de transmissão, o que permite o intercâmbio de energia e conseqüentemente obtendo ganhos sinérgicos, pelo balanceamento no uso das fontes geradoras de energia o que aumenta a eficiência do sistema e reduz os custos relacionados à geração de energia. Além disso, esta integração do sistema diminui os riscos de interrupção de energia elétrica no Brasil (ONS, s.d.[c]) . As Figura 2 e Figura 3 mostram o mapa do SIN em 2022 e a projeção para 2024, respectivamente.

Figura 2 – Mapa do Sistema Interligado Nacional em 2022



Fonte: (ONS, s.d.[a])

Figura 3 – Mapa de Expansão do Sistema Interligado Nacional Horizonte 2024



Fonte: (ONS, s.d.[b])

2.1.3 Ambientes de contratação

Com a criação da Lei 10.848 / 04, formou-se novos ambientes para a comercialização de energia no setor elétrico nacional. Até aquele ponto, a energia elétrica brasileira que era comercializada de maneira centralizada passou a ser comercializada em dois ambientes distintos, o ambiente de contratação regulado (ACR) e o ambiente de contratação livre (ACL) (SILVA, 2011).

- Ambiente de Contratação Livre (ACL)

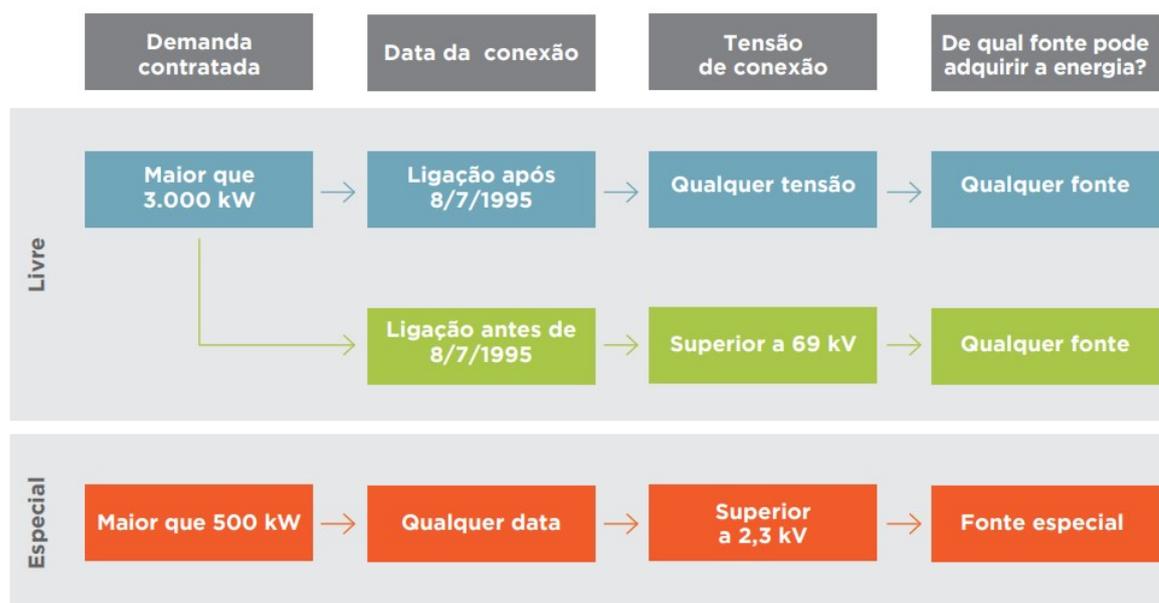
O Ambiente de Contratação Livre (ACL) pode ser definido com o segmento do mercado em que os consumidores podem escolher, de maneira livre, de qual gerador, distribuidor ou comercializador eles querem comprar o seu montante de energia, exercendo assim o seu direito à portabilidade da conta de luz.

A negociação das condições de contratação da quantidade de energia demandada é realizada de maneira exclusiva por contratos bilaterais livremente negociados, no qual esses tentam, da melhor maneira possível, contemplar os anseios e desejos do consumidor. É importante salientar que estes acordos devem ser obrigatoriamente registrados na CCEE.

No ACL, estão inseridos dois tipos de consumidores: os consumidores livres e os consumidores especiais. O primeiro deve possuir uma demanda de, no mínimo, 1000 kw a partir de janeiro de 2022 ou 500 kw a partir de janeiro de 2023 e pode comprar energia de qualquer fonte de geração. Já os consumidores especiais devem ter uma necessidade energética entre 500 e 3000 kw e só podem negociar energia proveniente de fontes renováveis, como: eólica, solar, biomassa e pequenas hidrelétricas (ABRACEEL, s.d.).

A Figura 4 apresenta um fluxograma simplificado, que indica a diferença básica entre ambos consumidores do ambiente livre.

Figura 4 – Diferenças entre o consumidor livre e o especial



Fonte: (ABRACEEL, s.d.)

- Ambiente de contratação Regulado (ACR)

Como citado anteriormente na subseção 2.1.3, há no Brasil dois ambientes de contratação de energia elétrica. O primeiro deles é o Ambiente de Contratação Regulada ou Mercado Cativo, onde participam apenas as empresas geradoras de energia elétrica e os agentes de distribuição, como por exemplo a Celesc. Estas últimas, tem como objetivo, comprar uma quantidade de energia elétrica para os consumidores de sua área de concessão, chamados de consumidores cativos. Neste ambiente, a compra e venda de energia se dá por meio de leilões organizados pela (CCEE) e regulamentados pela (ANEEL) e o vencedor desses eventos de licitação serão as empresas geradoras que oferecerem energia pelo menor preço. Vale ressaltar, que o preço da energia contratada no leilão é repassado para os consumidores cativos (SICARI, 2021).

Na Figura 5 tem-se a comparação dos ambientes de contratação.

Figura 5 – Diferenças entre o ambiente livre e o regulado

	 AMBIENTE LIVRE	 AMBIENTE REGULADO
 PARTICIPANTES	Geradoras, comercializadoras, consumidores livres e especiais	Geradoras, distribuidoras e comercializadoras. As comercializadoras podem negociar energia somente nos leilões de energia existente - (Ajuste e A-1)
 CONTRATAÇÃO	Livre negociação entre os compradores e vendedores	Realizada por meio de leilões de energia promovidos pela CCEE, sob delegação da Aneel
 TIPOS DE CONTRATO	Acordo livremente estabelecido entre as partes	Regulado pela Aneel, denominado Contrato de Comercialização de Energia Elétrica no Ambiente Regulado (CCEAR)
 PREÇO	Acordado entre comprador e vendedor	O preço da compra da energia é estabelecido no leilão e o preço da venda é pela ANEEL

Fonte: (ENERGES, s.d.)

2.1.4 Mercado de Curto Prazo de Energia

De forma geral, o Mercado de Curto Prazo (MCP), também conhecido como Mercado Spot, é um momento do mês onde os consumidores e geradores definem a quantidade de energia e fazem as adaptações necessárias de compra e venda para alcançar o balanço energético mensal (CCEE, s.d.[a]).

Ainda de acordo com CCEE (s.d.[a]), o MCP é um ambiente dinâmico onde acontece a medição das diferenças entre o volume de energia contratado e volume de energia gerado ou consumido e onde estudam-se as estratégias de operação.

Caso uma empresa compre mais energia do que utiliza em um determinado mês, essa sobra será liquidada ao chamado PLD (preço de liquidação das diferenças). Porém, essa liquidação é facultativa ao consumidor, visto que existe a possibilidade de venda desse excedente de energia para um agente comercializador.

Em muitos casos, é possível ainda ter um prêmio em relação ao preço PLD, tornando ainda mais vantajoso vender a energia excedente do que deixar liquidar na Câmara de Comercialização de Energia Elétrica (CCEE)

2.1.5 Custo Marginal de Operação

O Custo Marginal de Operação (CMO) é uma métrica usada no sistema elétrico brasileiro para calcular o custo de produção do próximo Megawatt-hora (MWh) necessário para atender a demanda adicional de energia no Sistema Interligado Nacional (SIN). Ou seja, o CMO representa o valor monetário necessário para gerar e fornecer uma quantidade adicional de eletricidade no SIN, assegurando que todas as necessidades de consumo sejam satisfeitas. Este cálculo é essencial para determinar os custos associados à produção de energia extra em diferentes submercados dentro do sistema elétrico (FORTUNATO *et al.*, 1990).

Ainda segundo Fortunato *et al.* (1990), o custo marginal pode ser dividido em custo marginal de curto prazo e custo marginal de longo prazo. O custo marginal de curto prazo, ou custo marginal de operação, é o custo do atendimento ao sistema sem a necessidade de construir ou adicionar novas instalações. Já o custo marginal de longo prazo ou custo marginal de expansão é o custo de atendimento ao diferencial de carga, considerando obras adicionais no sistema.

Por fim, os valores do CMO abrangem o estado dos reservatórios, a previsão de chuvas, o consumo de energia, o preço de combustíveis das usinas térmicas, geração de energia em termelétricas e hidrelétrica, a entrada de novos projetos de geração e a disponibilidade de transmissão e geração.

2.1.6 Preço da Liquidação das Diferenças

O Preço de Liquidação das Diferenças (PLD) atua como uma ferramenta na gestão e na operacionalização do mercado de energia elétrica brasileiro, especialmente no mercado de curto prazo. Ele representa o preço da energia elétrica no mercado de curto prazo, sendo utilizado para liquidar as diferenças entre o montante de energia que os agentes se comprometeram a comprar ou vender e o que foi efetivamente gerado ou consumido (CCEE, s.d.[a]).

Como descrito por CCEE (s.d.[a]), o PLD, Preço de Liquidação das Diferenças, é uma importante variável para o mercado de energia. É o preço base para as contratações de curto prazo e a referência nas negociações de médio e longo prazo.

O PLD também é utilizado para valorar a energia liquidada na CCEE, ou seja, aquela resultante da diferença entre a energia gerada ou contratada e a efetivamente consumida pelos agentes setoriais.

O PLD médio de cada submercado é calculado com base na média proporcional de cada patamar e semana. Todos os contratos de energia no mercado de curto prazo utilizam o PLD médio mensal do seu respectivo submercado, considerando também o acréscimo ou desconto, conforme o tipo de energia (CCEE, s.d.[a]).

O PLD é calculado com base nos Custos Marginais da Operação (CMO) e também

no patamar de carga. Os três patamares de divisão são: pesado (horário de alto consumo), médio (médio consumo) e leve (baixo consumo).

Diversos trabalhos, similares a este, utilizam diferentes variáveis de entrada para a previsão do PLD. A Tabela 1, abaixo, sintetiza as variáveis utilizadas por alguns autores.

Tabela 1 – Comparação das variáveis de entrada dos autores

Autor	Variáveis de entrada
Lagasse (2020b)	Energia Natural Afluente, Energia Armazenada, Geração Hidroelétrica, Geração Termelétrica, Geração Eólica, Intercâmbio de Energia entre os submercados e Demanda de Energia e PLD
Souza Mendonça, Silva e Bornia (2022)	condições hidrológicas, demanda de energia, preços de combustível, custo de déficit, entrada de novos projetos e disponibilidade de geração e transmissão
Cardoso <i>et al.</i> (2021)	Energia Natural Afluente, Energia Armazenada, Geração Hidroelétrica, Geração Termelétrica, Geração Eólica, Intercâmbio de Energia entre os submercados e Demanda de Energia e PLD
Belentani (2023)	Custo marginal de operação, demanda máxima de energia e energia armazenada
Capeletti (2019)	Vazão afluente, Vazão natural, Vazão, Vazão vertida, Vazão defluente, Cota, Volume útil
Lopes <i>et al.</i> (2022)	PLD, Energia Natural Afluente, Energia Armazenada, Precipitação Observada

Fonte: Próprio autor (2023)

2.1.7 Modelos de otimização e formação de preços

- NEWAVE

O Modelo de Despacho Hidrotérmico a Subsistemas Equivalentes – NEWAVE é a ferramenta responsável por elaborar os estudos de planejamento da etapa de médio prazo. Neste modelo o parque hidrotérmico é representado de forma agregada, o que significa que todos os reservatórios de um subsistema são agregados, ficando reduzidos a apenas 4 reservatórios equivalentes, um para cada região do SIN. Depois de agregar os reservatórios é determinada a política de operação mais econômica para os subsistemas equivalentes,

levando-se em conta as incertezas das afliências futuras, os patamares de demanda e a indisponibilidade dos equipamentos, CEPEL (s.d.). E por fim, ele simula a operação do sistema ao longo do período de planejamento para diversos cenários de sequências hidrológicas.

Para a definição das estratégias futuras da operação, o Modelo NEWAVE percorre diversos cenários hidrológicos para o horizonte de 5 anos e verifica o estado do SIN para cada um desses cenários

- DECOMP

O modelo DECOMP é utilizado no Programa Mensal da Operação do Sistema Interligado Nacional – PMO, que tem como principal objetivo estabelecer as metas e diretrizes energéticas de curto prazo da operação coordenada do SIN, assegurando a otimização dos recursos de geração disponíveis. O DECOMP traça as metas de geração para cada usina, de forma individualizada. Entretanto, por receber o valor de custo obtido pelo NEWAVE, que agrega todas as usinas de um subsistema, o modelo de curto prazo acaba calculando um custo marginal para cada um dos subsistemas. Este custo de operação é composto pelos gastos com combustíveis nas unidades térmicas e eventuais penalizações pelo não atendimento da demanda (CEPEL, s.d.).

- DESSEM

O DESSEM é o modelo responsável pela Programação Diária de Energia (PDO) do sistema de energia elétrica. Para isso, trabalha com técnicas e ferramentas que podem modelar e resolver o problema de otimização diária da operação do SIN, considerando não apenas aspectos da rede elétrica, mas também das operações das usinas do sistema, buscando fazê-lo da forma mais acurada possível (CEPEL, s.d.).

Análoga à situação anterior, aqui também, o DESSEM é acoplado ao DECOMP, através de um conversor de dados chamado DECODESS. Além disso, é importante destacar a relevância do DESSEM no contexto deste trabalho, pois ao alterar quais usinas são utilizadas para atender a demanda, ele influencia o custo marginal de produzir energia elétrica adicional no sistema e consequentemente no PLD (CEPEL, s.d.).

2.2 HOLT-WINTERS

De acordo com Verissimo *et al.* (2013), métodos estatísticos de previsão por séries temporais são instrumentos utilizados para projetar os comportamentos futuros, com base nas informações passadas da série, tendo como finalidade mitigar o risco na tomada de decisões. Fazer previsões então envolve certo risco, uma vez que as mesmas apresentam erros que variam com o sistema de previsão utilizado. Para Henning, Alves e Konrath

(2010) a base desses métodos é reconhecer o padrão da série, isolando-o do ruído presente nas observações individuais, e empregá-lo para prever os valores futuros da série.

Uma série temporal pode ter até quatro características diferentes em seu desempenho: média, sazonalidade, ciclo e tendência. A sazonalidade da série ocorre quando padrões cíclicos acontecem repetidamente em intervalos constantes de tempo. Já a característica cíclica ocorre quando a série possui flutuações ascendentes e descendentes em intervalos não regulares de tempo. Por fim, a tendência ocorre quando a série apresenta comportamento ascendente ou descendente por um período de tempo PELLEGRINI e FOGLIATTO (2001). Complementando, Wheelwright, Makridakis e Hyndman (1998) afirmam que a escolha do método a ser aplicado varia conforme o comportamento da série temporal que se quer analisar.

Quando os dados apresentam uma tendência ou sazonalidade, métodos de suavização exponencial são utilizados para fazer previsões, através das médias ponderadas de observações passadas, com os pesos diminuindo exponencialmente ao passo que a observações se tornam mais antigas (HYNDMAN; ATHANASOPOULOS, 2018).

De acordo com Omar e Kawamukai (2021), há três tipos de suavização exponencial: simples, dupla e tripla. O modelo de suavização simples é utilizado para dados sem tendência ou componente sazonal, enquanto que o método de suavização exponencial dupla é aplicado a dados que possuem alguma tendência. Por último se tem o método de suavização exponencial tripla, também conhecido como modelo de Holt-Winters, em que este é útil para produzir séries temporais suavizadas por capturar os componentes de tendência e sazonalidade.

O método de Holt-Winters é uma ampliação do modelo Holt (1957) desenvolvida por Winter em 1960. Devido ao seu fácil entendimento, boa acurácia, baixo custo de operação e com uma capacidade de ajuste automático e rápido a mudanças na série em observação o modelo de suavização exponencial tripla é um dos métodos mais utilizados para previsões de curto prazo (MORETTIN; TOLOI, 2022).

Existem dois métodos principais de Holt-Winters, que diferem pela forma como a sazonalidade é modelada, classificados como aditivo e multiplicativo. O modelo multiplicativo onde a amplitude da variação sazonal cresce ou decresce como função do tempo e o modelo de Holt-Winters aditivo, onde a amplitude da variação sazonal não varia ao longo do tempo. Portanto o método aditivo é mais adequado quando as variações sazonais são aproximadamente constantes, enquanto o método multiplicativo é preferido quando as variações sazonais estão mudando proporcionalmente ao nível da série (HYNDMAN; ATHANASOPOULOS, 2018). Fórmulas dos modelos aditivo e multiplicativo na Tabela 2 abaixo.

Tabela 2 – Equações dos Modelos de Holt-Winters

Componente/Modelo	Holt-Winters Aditivo	Holt-Winters Multiplicativo
Nível	$L_t = \alpha(Y_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + b_{t-1})$	$L_t = \alpha \frac{Y_t}{S_{t-m}} + (1 - \alpha)(L_{t-1} + b_{t-1})$
Tendência	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$
Sazonalidade	$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-m}$	$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-m}$
Previsão	$Y_{t+h} = L_t + hb_t + S_{t-m+h_m}$	$Y_{t+h} = (L_t + hb_t)S_{t-m+h_m}$

Fonte: Próprio autor a partir de (HYNDMAN; KOEHLER *et al.*, 2008)

Sendo:

- S – Comprimento da Sazonalidade
- L_t – Nível da Série
- b_t – Tendência
- S_t – Componente Sazonal
- F_{t+m} – Previsão para o período m
- Y_t – Valor Observado

2.3 SARIMA

Os modelos de Box-Jenkins, genericamente conhecidos por *Auto Regressive Integrated Moving Averages* (ARIMA) são definidos pela combinação dos componentes estatísticos de autorregressão, integração e médias móveis. O componente autorregressivo (AR) indica que a variável a ser observada pode ser determinada com base em seus valores passados. O componente integrado (I) faz referência à diferença entre os valores atuais e anteriores, esta parte pode ser aplicada mais de uma vez. Por último, o componente de médias móveis (MA) emprega os valores históricos recentes da série temporal para estimar o valor futuro (BOX *et al.*, 2015).

Segundo Morettin e Toloi (2022) o modelo ARIMA possui três ordens de comando p , d e q , em que essas representam, respectivamente, os componentes autorregressivo, integrado e média móveis, cuja variação pode influenciar diretamente no resultado geral da análise temporal. A combinação do modelo autorregressivo e de média móvel com a aplicação da integração resulta no modelo ARIMA de ordem (p, d, q) , demonstrado na equação 1, sendo um dos modelos mais populares para análise de previsão de séries temporais (ZHANG, 2003).

$$\Delta^d Z_t = \delta + \sum_{i=1}^p \phi_i \Delta^d Z_{t-i} + \sum_{i=1}^q \theta_i e_{t-i} + e_t \quad (1)$$

onde:

- Δ^d é o operador de diferenciação de ordem d .
- Z_t é a série temporal no tempo t .
- ϕ_i são os coeficientes do componente autoregressivo.
- θ_i são os coeficientes da componente de média móvel.
- e_t é o erro no tempo t .
- δ é uma constante.

De acordo com FAVA *et al.* (2000), a ordem p pode ser determinada observando-se o instante em que as autocorrelações encontram-se dentro do limite estabelecido. O mesmo é verdade para determinar a ordem q , porém presenciando o mesmo comportamento em relação as autocorrelações.

Uma variação do modelo ARIMA usado para comportar a sazonalidade é o ARIMA Sazonal ou SARIMA, representado na equação 2 abaixo. Este modelo possui uma parte não sazonal com parâmetros (p, d, q) , oriunda do ARIMA, e uma sazonal com parâmetros $(P, D, Q)_S$. Sendo, P a relação sazonal entre uma observação e suas defasagens, D o número de diferenças sazonais necessárias para tornar a série estacionária, Q a relação sazonal entre uma observação e o erro residual de uma média móvel aplicada a observações defasadas e com a letra S representando a duração do período sazonal (BOX *et al.*, 2015).

$$\Delta^d \Delta_s^D Z_t = \delta + \sum_{i=1}^p \phi_i \Delta^d Z_{t-i} + \sum_{i=1}^q \theta_i e_{t-i} + \sum_{i=1}^P \Phi_i \Delta_s^D Z_{t-si} + \sum_{i=1}^Q \Theta_i e_{t-si} + e_t \quad (2)$$

Sendo:

- $\Delta^d Z_t$:
 - Representa a série temporal Z_t diferenciada d vezes de maneira não sazonal.
- $\Delta_s^D Z_t$:
 - Representa a série temporal Z_t diferenciada D vezes de maneira sazonal.
- δ :
 - É o termo constante na equação.
- $\sum_{i=1}^p \phi_i \Delta^d Z_{t-i}$:

- Representa o componente autoregressivo (AR) da equação.
- ϕ_i são os coeficientes autoregressivos não sazonais.
- $\Delta^d Z_{t-i}$ é a série temporal diferenciada com defasagem i .
- $\sum_{i=1}^q \theta_i e_{t-i}$:
 - Representa o componente da média móvel (MA) da equação.
 - θ_i são os coeficientes da média móvel não sazonais.
 - e_{t-i} é o erro ou perturbação com defasagem i .
- $\sum_{i=1}^P \Phi_i \Delta_s^D Z_{t-si}$:
 - Representa o componente autoregressivo sazonal da equação.
 - Φ_i são os coeficientes autoregressivos sazonais.
 - $\Delta_s^D Z_{t-si}$ é a série temporal diferenciada sazonalmente com defasagem sazonal si .
- $\sum_{i=1}^Q \Theta_i e_{t-si}$:
 - Representa o componente da média móvel sazonal da equação.
 - Θ_i são os coeficientes da média móvel sazonais.
 - e_{t-si} é o erro ou perturbação com defasagem sazonal si .
- e_t :
 - É o erro ou perturbação no tempo t .

2.4 REDES NEURAI

Redes neurais são um tipo de algoritmo *Machine learning* inspirado em redes neurais biológicas do cérebro. De acordo com Goodfellow, Bengio e Courville (2016), redes neurais são compostas por camadas de nós interconectadas, que são compostos por um *layer* de entrada, um ou mais *layers* ocultos e um *layers* de saída. A primeira camada recebe os dados de entrada, no qual esses são transformados pelas camadas ocultas antes de serem enviadas pela camada de saída. As conexões entre os nós são ponderadas e os pesos podem e devem ser ajustados durante a fase de treinamento.

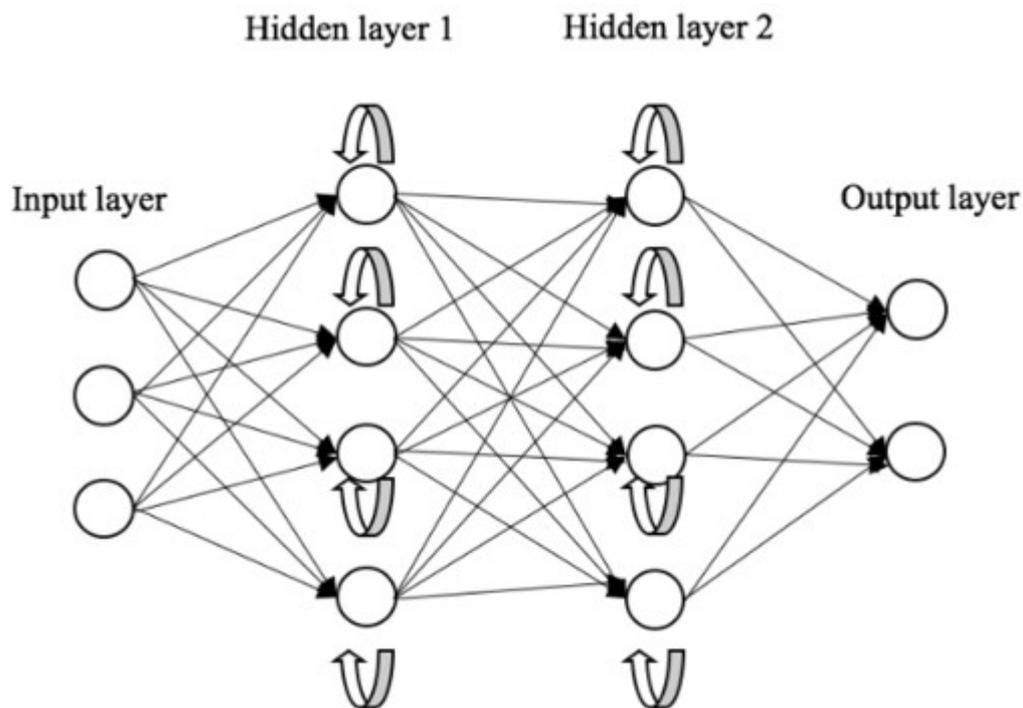
Uma das principais vantagens das rede neurais é a sua capacidade de aprender com dados e generalizar padrões para dados invisíveis e novos. Isso é feito pelo processo de *backpropagation*, que corresponde em ajustar os pesos das conexões entre os nós, com base em erros realizados durante o treinamento. Esse processo iterativo permite que a rede melhore suas previsões e precisão, continuamente, fazendo com que o erro entre a saída prevista e saída real seja minimizado (RUMELHART; HINTON; WILLIAMS, 1986).

2.4.1 LSTM

Redes Neurais Recorrentes, também conhecida por RNN (do inglês *Recurrent Neural Networks*) são uma classe de modelos de redes neurais artificiais que possuem estado interno ou memória de curto prazo devido a conexões de *feedback* recorrentes, tornando-as adequadas em reconhecer padrões em sequencia de dados, como classificação de fala, previsão e geração (WILLIAMS, 1989).

Segundo Medsker e Jain (2001), o RNN possui um mecanismo cíclico no qual cada neurônio recebe duas entradas. Uma oriunda dos neurônios da camada anterior e outra originada de eventos prévios, em que esta é denominada estado oculto ou *hidden state* e possui o estado inicializado em zero, como pode ser visto na Figura 6.

Figura 6 – A forma geral de uma RNN



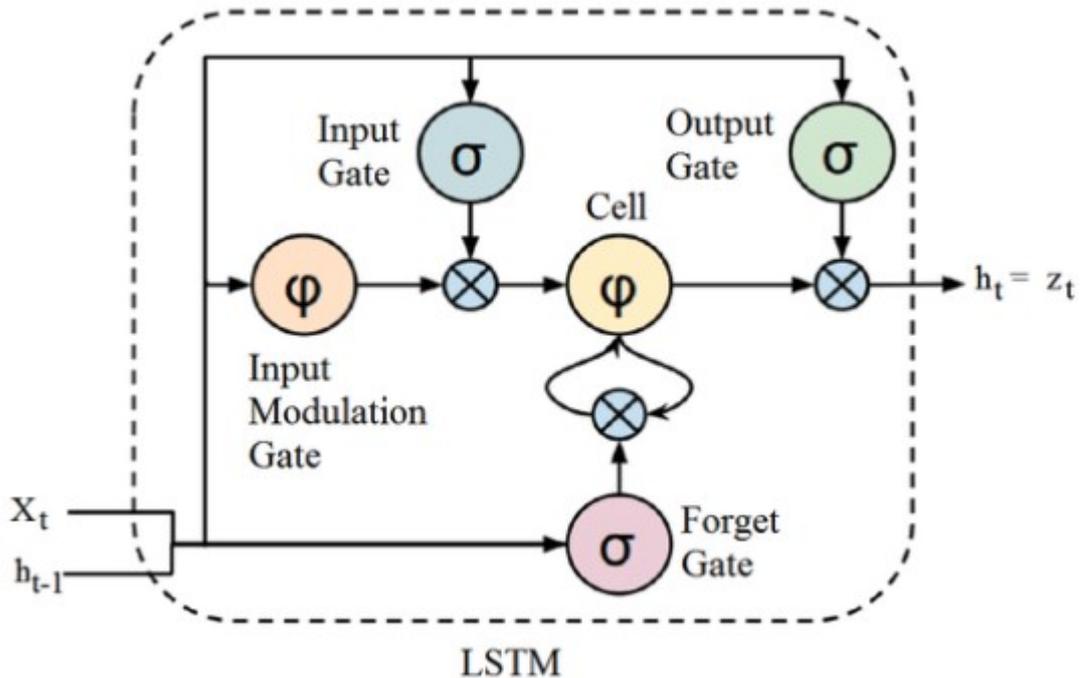
Fonte: (ODSC, 2023)

De acordo Hochreiter (1991) e Hochreiter, Bengio *et al.* (2001) RNNs simples enfrentam desafios ao aprender dependências de longo prazo, que abrangem mais de 10 etapas de tempo, devido a memória curta dos RNNs, o que faz com que os neurônios praticamente esqueçam dos estados passados e por consequência o ajuste dos pesos se torna minimamente eficaz. Este problema é conhecido como problema de gradiente de fuga (PASCANU; MIKOLOV; BENGIO, 2013).

Para resolver o problema de memória de dependências, citado anteriormente, Hochreiter e Schmidhuber (1997) criaram um modelo que possui alta capacidade de armazenamento de informações arbitrárias por um extenso intervalo de tempo, chamado de LSTM (do inglês *Long Short Term Memory*).

A LSTM é composta por uma sequência de dados que integra quatro componentes interativos, cada um correspondendo a uma operação neural específica, além de blocos de memória específicos, chamados de células, conforme ilustrado na Figura 7.

Figura 7 – Estrutura da rede LSTM



Fonte: (DEEPLARNINGBOOK, 2023)

Cada bloco pode possuir uma ou mais células de memória e três *gates*: entrada (*input*), saída (*output*) e esquecimento (*forget*). Segundo Gers, Schmidhuber e Cummins (2000) o *forget gate* decide qual informação do estado da célula anterior deve ser mantida ou descartada, através de uma função sigmoideal, gera um valor entre 0 e 1, um valor próximo de 0 significa que o dado deve ser esquecido, e um valor próximo de 1 mantêm o dado.

Já o *input gate* atualiza o estado da célula com novas informações, através da combinação de duas funções, uma sigmoideal que decide quais valores devem ser atualizados e uma função de tangente hiperbólica que cria um vetor com os novos valores candidatos que podem ser adicionados ao estado da célula. Por último se tem o *output gate* que decide qual informação do estado atual da célula deve ser transmitida como saída, por meio de uma função sigmoideal e de uma função de tangente hiperbólica para determinar e ajustar a informação que será transmitida do estado atual da célula para a próxima etapa ou camada (SHERSTINSKY, 2020). Mais detalhes do modelo LSTM podem ser vistos na obra *Learning to forget: Continual prediction with LSTM*, página 2451 a 2471, do autor Gers, Schmidhuber e Cummins (2000).

2.5 MÉTRICAS DE ERRO

A seleção de métricas de erro para mensurar a precisão e desempenho das previsões de uma série temporal ao longo do tempo é crucial, pois os modelos são continuamente refinados para otimizar essas medidas. Além disso, elas são usadas para identificar o modelo que se adapta melhor aos dados. Conforme apontado por Antonanzas *et al.* (2016), um modelo pode ter seu desempenho e exatidão avaliados por meio de diversas métricas.

Portanto ao longo do capítulo 4, o desempenho dos modelos escolhidos serão avaliados a partir de quatro métricas diferentes

2.5.1 MAPE

O *Mean Absolute Percentage Error* (MAPE) ou Erro Percentual Absoluto Médio é utilizado para informar, em média, o quanto a previsão foge da realidade no nível de agregação de cálculo, sem a compensação de erros de negativos e positivos. Makridakis (1993) enfatiza que métricas percentuais oferecem *insights* comparativos valiosos, especialmente quando se comparam séries temporais de diferentes magnitudes ou unidades.

$$\text{MAPE} = \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{|y_i|} \times \frac{100\%}{n} \quad (3)$$

2.5.2 MAE

O erro absoluto médio (MAE - *mean absolute error*) é outra métrica útil amplamente utilizada em avaliações de modelos. Hyndman e Koehler (2006) argumentam que o MAE é particularmente útil pois fornece uma medida clara da magnitude dos erros, sem dar um foco indevido a grandes erros, tornando-o menos sensível a *outliers* do que outras métricas

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4)$$

2.5.3 MSE

O Erro Médio Quadrático (MAE - *Mean Square Error*) é valorizado porque pune mais fortemente grandes erros. Isto faz com que o MSE seja, especialmente, útil em contextos onde erros grandes são considerados muito problemáticos. Reafirmando, Willmott e Matsuura (2005) informam que o MSE pode ser mais apropriado em situações onde os erros grandes têm consequências desproporcionalmente grandes.

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

2.5.4 RMSE

Usualmente utilizada para avaliar modelos de regressão, Raiz do Erro Médio Quadrático ou RMSE (do inglês *Root Mean Square Error*) tem o atrativo de ser expresso nas mesmas unidades da variável alvo, o que facilita sua interpretação. Mais do que isso, a raiz quadrada introduzida na métrica enfatiza os grandes erros, fazendo com que modelos que cometam erros grandes sejam mais penalizados (GÉRON, 2022).

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (6)$$

Para as Fórmulas 3, 4, 5 e 6 tem-se :

- N : Número total de observações.
- y_i : Valor observado para a i -ésima observação.
- \hat{y}_i : Valor previsto para a i -ésima observação.

3 METODOLOGIA

Neste Capítulo será abordado a metodologia de pesquisa utilizada tanto no desenvolvimento quanto na realização do estudo proposto, sendo este capítulo dividido em duas seções: a Seção 3.1 indica a classificação do trabalho quanto ao tipo de pesquisa e a Seção 3.2 informa as etapas metodológicas do mesmo.

3.1 CLASSIFICAÇÃO DA PESQUISA

Para Gil *et al.* (2002) um trabalho de pesquisa pode ser classificado em relação a quatro aspectos: (I) natureza, (II) forma de abordagem, (III) propósito e (VI) procedimentos técnicos. Desta maneira, aplicou-se a classificação proposta por Gil *et al.* (2002), para categorizar este trabalho de conclusão de curso.

Quanto ao ponto de vista da sua natureza, a seguinte pesquisa é categorizada como aplicada uma vez que este estudo busca prover uma aplicação prática de ferramentas de previsão para a resolução de um problema, que não seja o próprio conhecimento, mas sim um problema específico, a previsão do preço de liquidação diário de energia no Brasil.

No que se refere a forma de abordagem, esse estudo é classificado como quantitativo, onde o desenvolvimento da pesquisa se dá pela, principalmente, utilização de processamento eletrônico que utiliza dados numéricos organizados em tabelas, o que permite o teste das hipóteses estatísticas (GIL *et al.*, 2002).

De acordo com o propósito, essa pesquisa é qualificada como explicativa, dado que visa identificar fatores que influenciam ou determinam o acontecimento de fenômenos, aprofundando assim o conhecimento da realidade (GIL *et al.*, 2002).

Por último, os procedimentos técnicos deste trabalho de conclusão de curso podem ser classificados tanto como uma pesquisa bibliográfica, quanto experimental. Já que para entender e apresentar o PLD, usou-se livros, artigos, sites para construir todo o referencial teórico e, conforme Gil *et al.* (2002), utilizou-se da pesquisa experimental para testar as possíveis combinações e ponderações de variáveis que podem influenciar nos métodos de previsão adotados e nas suas métricas de controle.

3.2 ETAPAS METODOLÓGICAS

Com o intuito de contemplar os objetivos propostos na seção 1.2, o seguinte trabalho foi estruturado em 6 etapas, conforme pode ser observado na Figura 8.

Figura 8 – Etapas metodológicas



Fonte: Elaborado pelo Autor (2023)

O processo utilizado em cada uma das etapas metodológicas é apresentado de forma mais detalhada nas próximas subseções, entretanto vale salientar as principais ferramentas utilizadas no desenvolvimento deste trabalho, são elas:

- a. Jupyter lab e Google Colab como Ambiente de desenvolvimento integrado (IDE);
- b. Python como a linguagem de programação;
- c. Numpy, Pandas, Datetime e Excel como as bibliotecas e programas para o tratamento, limpeza e estruturação dos dados;
- d. Statsmodels como biblioteca de implementação dos modelos SARIMA e Holt-Winters
- e. Tensorflow e Keras como as bibliotecas de aprendizado de máquina para implementação do modelo LSTM;
- f. Sklearn.metrics como bibliotecas para a análise do desempenho dos modelos pela métricas MAPE, MAE, MSE e RMSE
- g. Matplotlib, GGplot como as bibliotecas de visualização de dados e para a análise exploratória das variáveis tanto de entrada quando de saída;

3.2.1 Etapa 1: Revisão Bibliográfica

A primeira etapa dos procedimentos metodológicos é composta pela revisão da literatura sobre as temáticas mercado de energia brasileiro, redes neurais e métricas de erros, através de livros, artigos, dissertações etc. Esta, além de prover a base para toda a pesquisa, também ajudou na realização do primeiro objetivo específico que busca identificar as variáveis que influenciam na formação do preço de liquidação das diferenças, como pode ser visto na Tabela 1 da seção 2.1.6.

3.2.2 Etapa 2: Coleta de dados

A segunda etapa envolveu a coleta de dados. As variáveis de entrada utilizadas no presente trabalho foram o PLD, CMO e geração em termelétricas, em que se utilizou de dados históricos do Planejamento da Operação do Sistema Elétrico Brasileiro, divulgadas na CCEE e no ONS. Tanto o CMO, quanto a geração em termelétricas foram selecionadas por possuírem uma discretização horária.

Para fazer a coleta dos dados históricos do PLD a CCEE disponibiliza a página “Painel Preços”, no qual diversas aquisições relacionadas ao mercado de energia são demonstradas. Além disso, a página possibilita a seleção dos dados por data (CCEE, s.d.[b]).

Já os demais dados, Produção de energia das usinas termelétricas e custo marginal de operação, foram obtidos através da página “Dados Abertos” do ONS, disponibilizado pelo próprio operador nacional do sistema elétrico em (ONS, 2022).

3.2.3 Etapa 3: Adequação dos dados

Para efetuar as previsões do PLD, para mercado do SIN, as variáveis selecionadas passaram por um processo de agrupação e padronização com o objetivo de adequar os dados de entrada dos modelos.

Vale frisar que as variáveis foram tratadas, para a discretização horária, pois o *target* do modelo, o PLD é fornecido desta maneira pela CCEE.

Por fim, foram utilizadas as bibliotecas Numpy, Pandas e Datetime, da linguagem Python, para o tratamento, limpeza e estruturação dos dados.

3.2.4 Etapa 4: Seleção das variáveis do modelo LSTM

O LSTM comporta mais de uma variável enquanto o Holt-Winters e SARIMA não. Portanto buscou-se verificar quais dos modelos LSTM apresenta o melhor desempenho. Foram utilizadas as bibliotecas Tensorflow e Keras para a análise exploratória das variáveis de entrada.

A partir dos dados tratados e clusterizados nas sub-seções 3.2.2 e 3.2.3, procurou-se uma maior compreensão sobre a totalidade dos dados. Em suma, a etapa 4 compreende-se por analisar quais foram as variáveis que participaram do modelo de previsão LSTM. Com

isso também se atinge o objetivo específico 2, verificar a influência do custo marginal de operação e da geração em usinas térmicas na formação do PLD.

3.2.5 Etapa 5: Aplicação dos modelos selecionados

A etapa 5 da pesquisa é o treinamento e teste dos modelos propostos (Holt-Winters, SARIMA e LSTM) e está associado ao quarto objetivo específico. Para a modelagem do problema utilizou-se as bibliotecas Statsmodels, Tensorflow e Keras como as bibliotecas para a implementação dos modelos.

Os dados tratados na etapa 3 foram divididos em dois subconjuntos diferentes: treinamento (75% da amostra) e previsão/validação (25% da amostra). O subconjunto de treinamento é utilizado para treinar o aprendizado da rede, enquanto a parte de previsão/validação será usado para aplicar o *backtest* do modelo treinado. Também foi aplicado aos modelos o *rolling forecast* como forma de aumentar a acurácia das previsões, permitindo uma atualização contínua dos modelos com base nos dados mais recentes.

3.2.6 Etapa 6: Avaliação dos modelos de previsão

Na etapa de avaliação dos modelos de previsão, a qual culmina na contemplação do quarto objetivo específico, a sistemática de avaliação de desempenho foi colocada em prática tendo em vista verificar a assertividade dos modelos criados.

Por conseguinte, essa etapa visou a verificação da existência de diferença de desempenho entre os modelos de aprendizado de máquina através das métricas de erro MAE, MSE, RMSE e MAPE.

4 RESULTADOS E DISCUSSÕES

Este capítulo tem como objetivo explicar os resultados obtidos a partir da implementação da metodologia e dos algoritmos percorridos no capítulo 3.

4.1 COLETA E LIMPEZA DOS DADOS

Os dados utilizados foram os valores históricos do Preço de Liquidação das Diferenças, a produção de energia das usinas termelétricas e o Custo Marginal de Operação. Desta forma, o primeiro passo consiste em obter dados históricos das três variáveis selecionadas.

Em 1º de janeiro de 2021 o PLD que antes era semanal passou a ser horário, porém mesmo tendo esta mudança opta-se por usar dados que vão de 1º de julho de 2020 a 31º de agosto de 2021 para aumentar o desempenho dos modelos e porque a CCEE oferta esses dados em discretização horária. Também é válido informar que por falta de grandes variações em longos períodos, como visto na Figura 9, os valores do PLD de 2022 e 2023 não foram considerados na análise.

Figura 9 – Variação do PLD 2022 e 2023



Fonte: CCEE (s.d.[b])

Os dados históricos do PLD foram obtidos, como citado na seção 3.2.2, na página “Dados e Análises” do site da CCEE.

Procedimentos para a preparação dos dados foram necessários, a fim de deixar a série histórica no formato adequado para que seja possível adicionar futuramente as demais variáveis e para utilizá-la nos modelos de previsão selecionados. Um dos principais tratamentos é a transformação da matriz dos valores históricos, Figura 10, numa tabela com as colunas "data", "hora", "sub-mercado" e "PLD". Outro processo foi a agrupação dos valores dos sub-mercados, neste, como efeito de simplificação, foi retirado uma média Aritmética dos valores do PLD de todos os sub-mercados, com o objetivo ter um único valor para todo o território brasileiro, como pode ser visto na Figura 11.

Figura 10 – Matriz dos valores históricos do PLD

Hora	Submercado	01/01/2020	02/01/2020	03/01/2020	04/01/2020	05/01/2020	06/01/2020	07/01/2020	08/01/2020	09/01/2020	10/01/2020
0	SUDESTE	286,03	291,34	291,33	361,2	357,12	363,23	366,05	369,35	366,04	366,5
0	SUL	286,03	291,34	291,33	361,2	357,12	363,23	366,05	369,35	366,04	366,5
0	NORDESTE	305,92	297,43	291,33	383,97	375,79	366,2	366,05	528,07	380,77	366,5
0	NORTE	286,03	291,34	291,33	361,2	357,12	363,23	366,05	369,35	366,04	366,5
1	SUDESTE	285,97	288,29	289,91	360,12	352,19	357,73	359,49	365,97	363,13	365,22
1	SUL	285,97	288,29	289,91	360,12	352,19	357,73	359,49	365,97	363,13	365,22
1	NORDESTE	342,56	291,77	289,91	366,34	359,35	373,44	359,49	519,52	382,34	365,22
1	NORTE	285,97	288,29	289,91	360,12	352,19	357,73	359,49	365,97	363,13	365,22
2	SUDESTE	285,76	285,26	288,91	359,04	346,58	357,29	356,32	363,94	360,77	363,26
2	SUL	285,76	285,26	288,91	359,04	346,58	357,29	356,32	363,94	360,77	363,26
2	NORDESTE	533,88	285,26	288,91	359,04	346,58	387,01	368,42	519,45	382,29	363,26
2	NORTE	285,76	285,26	288,91	359,04	346,58	357,29	356,32	363,94	360,77	363,26
3	SUDESTE	284,51	284,49	288,43	356,37	343,55	357,19	355,36	363,02	360,41	361,7
3	SUL	284,51	284,49	288,43	356,37	343,55	357,19	355,36	363,02	360,41	361,7
3	NORDESTE	344,49	284,49	288,43	356,37	439,43	380,22	528,21	519,53	389,77	361,7
3	NORTE	284,51	284,49	288,43	356,37	343,55	357,19	355,36	363,02	360,41	361,7
4	SUDESTE	283,06	284,02	288,46	355,62	341,3	357,54	355,51	361,98	360,41	361,52
4	SUL	283,06	284,02	288,46	355,62	341,3	357,54	355,51	361,98	360,41	361,52
4	NORDESTE	317,29	284,02	288,46	357,16	505,57	382,61	458,25	525,24	452,64	361,52

Fonte: CCEE (s.d.[b])

Figura 11 – Média Aritmética do PLD

	data	hora	nom_subsistema	pld		data	hora	media_pld
0	01/01/2020	0	NORTE	286,03	0	2020-01-01	00:00:00	291.0025
1	01/01/2020	1	NORTE	285,97	1	2020-01-01	01:00:00	300.1175
2	01/01/2020	2	NORTE	285,76	2	2020-01-01	02:00:00	347.7900
3	01/01/2020	3	NORTE	284,51	3	2020-01-01	03:00:00	299.5050
4	01/01/2020	4	NORTE	283,06	4	2020-01-01	04:00:00	291.6175
...
95	04/01/2020	23	NORTE	359,77	95	2020-01-04	23:00:00	361.2075
96	05/01/2020	0	NORTE	357,12	96	2020-01-05	00:00:00	361.7875
97	05/01/2020	1	NORTE	352,19	97	2020-01-05	01:00:00	353.9800
98	05/01/2020	2	NORTE	346,58	98	2020-01-05	02:00:00	346.5800
99	05/01/2020	3	NORTE	343,55	99	2020-01-05	03:00:00	367.5200

Fonte: Elaborado pelo Autor (2023)

A obtenção dos dados do Custo Marginal de operação e geração das usina termelétricas ocorreu a partir da delimitação do espaço temporal, citado no início desta seção, utilizando o Portal de Dados Abertos do ONS.

Para o pré-processamento dessas duas variáveis foi necessário alguns ajustes, tais como a troca de vírgula por ponto, como separador de casa decimal e também a agrupação dos valores dos sub-mercados para um único só, como foi feito com o PLD.

Com a base de dados das três variáveis limpas, utilizou-se a função "pd.merge" da biblioteca Pandas para unir as informações em um único *dataframes*, como pode ser visto na Figura 12.

Figura 12 – Unificação dos *dataframes*

	data	media_pld	media_cmo	media_dessem
0	2020-01-01 00:00:00	291.0025	2.864975e+10	3.256225e+11
1	2020-01-01 01:00:00	300.1175	2.864500e+10	3.246225e+11
2	2020-01-01 02:00:00	347.7900	2.863525e+10	3.247225e+11
3	2020-01-01 03:00:00	299.5050	2.870050e+10	3.229955e+11
4	2020-01-01 04:00:00	291.6175	2.865975e+10	3.220638e+11
...
95	2020-01-04 23:00:00	361.2075	3.552275e+10	2.873975e+11
96	2020-01-05 00:00:00	361.7875	3.534600e+10	2.988725e+11
97	2020-01-05 01:00:00	353.9800	3.516675e+10	2.988725e+11
98	2020-01-05 02:00:00	346.5800	3.475875e+10	2.989975e+11
99	2020-01-05 03:00:00	367.5200	3.467800e+10	2.989975e+11

Fonte: Elaborado pelo Autor (2023)

Com a finalização etapa de Coleta e limpeza dos dados, é possível gerar os gráficos do PLD, CMO e Geração das usinas térmicas, Figura 13, Figura 14, Figura 15, respectivamente.

Figura 13 – Média do PLD Brasil - 2020 e 2021



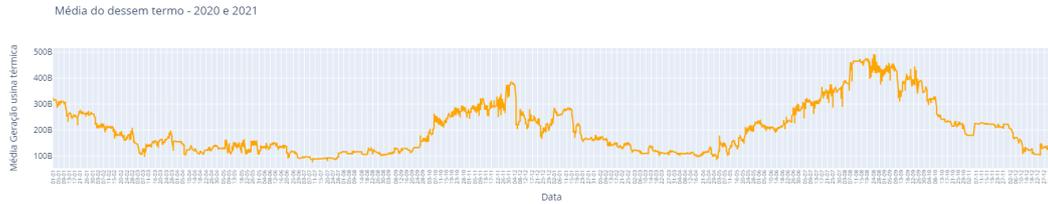
Fonte: Elaborado pelo Autor (2023)

Figura 14 – Média do CMO Brasil - 2020 e 2021



Fonte: Elaborado pelo Autor (2023)

Figura 15 – Média geração Usina termelétrica - 2020 e 2021



Fonte: Elaborado pelo Autor (2023)

4.2 APLICAÇÃO DOS MODELOS SELECIONADOS

A fim de permitir uma comparação entre os modelos escolhidos, algumas regras de implementação foram estabelecidas. A primeira delas é que os três modelos escolhidos fizeram o *forecast* para os 3 meses seguintes (1º de junho de 2021 a 31º de agosto de 2021), correspondente a 91 dias ou 2184 observações horárias. A segunda regra é que todos os modelos tiveram uma previsão rolante, prevendo sempre uma hora à frente ($t + 1$). E a última regra é que os modelos utilizaram um período sazonal de 24 observações ou uma sazonalidade diária.

4.2.1 Modelo de Holt-Winters

O método de Holt-Winters foi executado através da utilização do modelo ExponentialSmoothing, com adição de componente sazonal, da biblioteca Statsmodels.tsa.holtwinters. O modelo previu 2184 observações horárias.

O processo de *Rolling forecast* foi realizado utilizando parte do código da Figura 16, permitindo que o modelo de Holt-Winters se adapte de maneira dinâmica aos dados, ao passo em que as previsões vão sendo feitas.

Figura 16 – Código holt-winters com rolamento

```

Holt-Winters Exponential Smoothing (HWES) com rolamento

# Bibliotecas
from statsmodels.tsa.holtwinters import ExponentialSmoothing
from sklearn.metrics import mean_absolute_error, mean_squared_error

# Definição da frequência:
train_rolante_single_ts = train_rolante_single_ts.asfreq('H')
valid_rolante_single_ts = valid_rolante_single_ts.asfreq('H')

# Multi-step forecasts com reestimação (Rolling forecast)
hwes_forecasts_rolante = []
for step in range(h_holt_rolante):
    hwes_model = ExponentialSmoothing(train_rolante_single_ts, seasonal='add', seasonal_periods=24).fit()
    forecast = hwes_model.forecast(steps=1)[0]
    hwes_forecasts_rolante.append(forecast)

# Adicionar o valor ao conjunto de treinamento e seguir para a próxima previsão
train_rolante_single_ts = pd.concat([train_rolante_single_ts, valid_rolante_single_ts.iloc[[step]]])

hwes_forecasts_rolante = pd.Series(hwes_forecasts_rolante, index=valid_rolante_single_ts.index[:h_holt_rolante])

```

Fonte: Elaborado pelo Autor (2023)

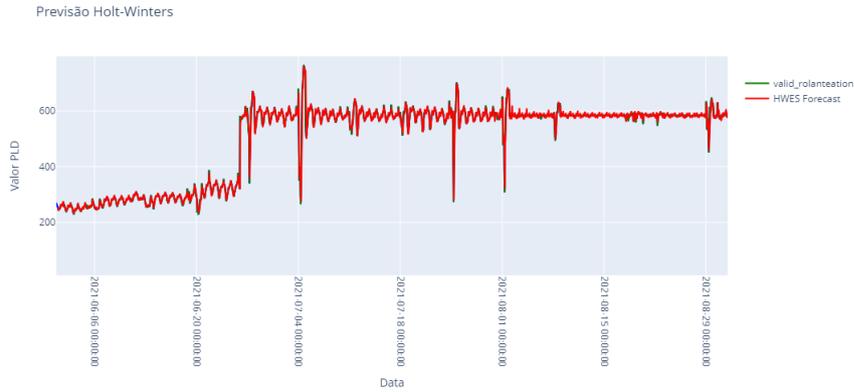
Sendo mais exaustivo, inicia-se o processo com a criação de uma lista vazia, chamada `hwes_forecasts_rolante`, em que esta armazenará as previsões que serão geradas. Após a criação da lista é iniciado um *loop* em que dentro deste há o modelo Holt-Winters construído a partir dos dados de treinamento. O método `ExponentialSmoothing` é usado para criar o modelo, e os parâmetros passados para ele são os dados de treinamento, denominados no código como `train_rolante_single_ts` e as informações sobre sazonalidade diária.

Após a construção do modelo, é iniciado o *forecast* de uma hora à frente ($t + 1$), através do acesso ao valor inicial da previsão. O valor real é então adicionado ao conjunto de treinamento, permitindo a adaptação do modelo aos dados observados. Este processo é repetido até concluir a previsão das 2184 observações horárias.

Após o término do *loop*, a lista com os valores do PLD previsto `hwes_forecasts_rolante` é convertida em uma série pandas, aonde o índice é definido como sendo os mesmos da série temporal de validação e prolongado 2184 passos à frente.

As métricas de erro obtidas foram: MAE de 7.031, MSE de 287.189, RMSE de 16.946 e um MAPE de 1.399%. O gráfico da previsão pode ser visto na Figura 17 abaixo.

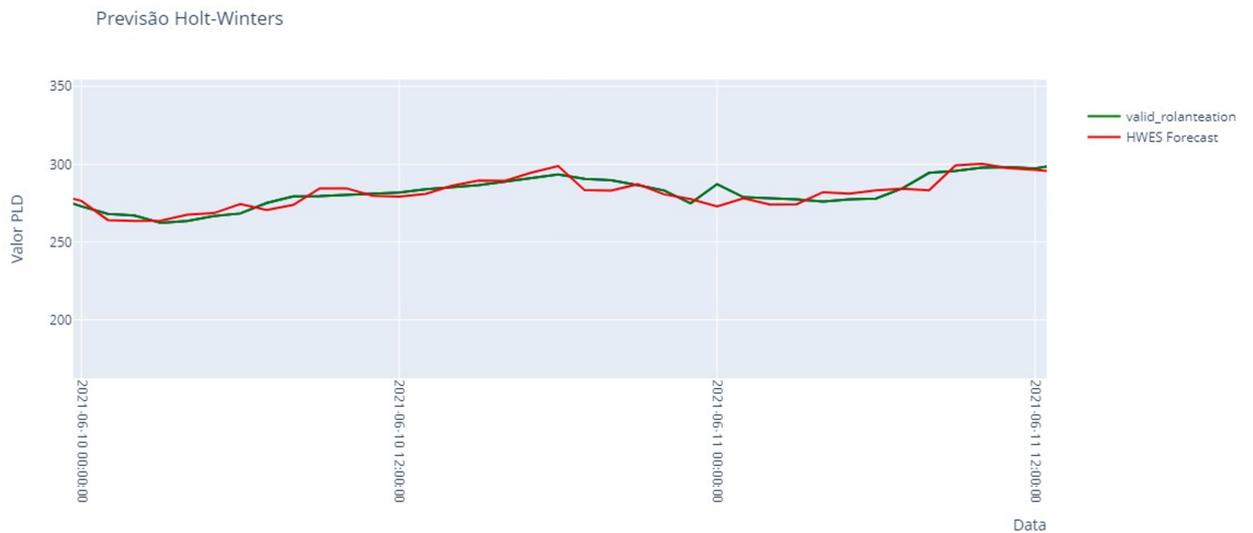
Figura 17 – Previsão Holt-Winters com rolamento



Fonte: Elaborado pelo Autor (2023)

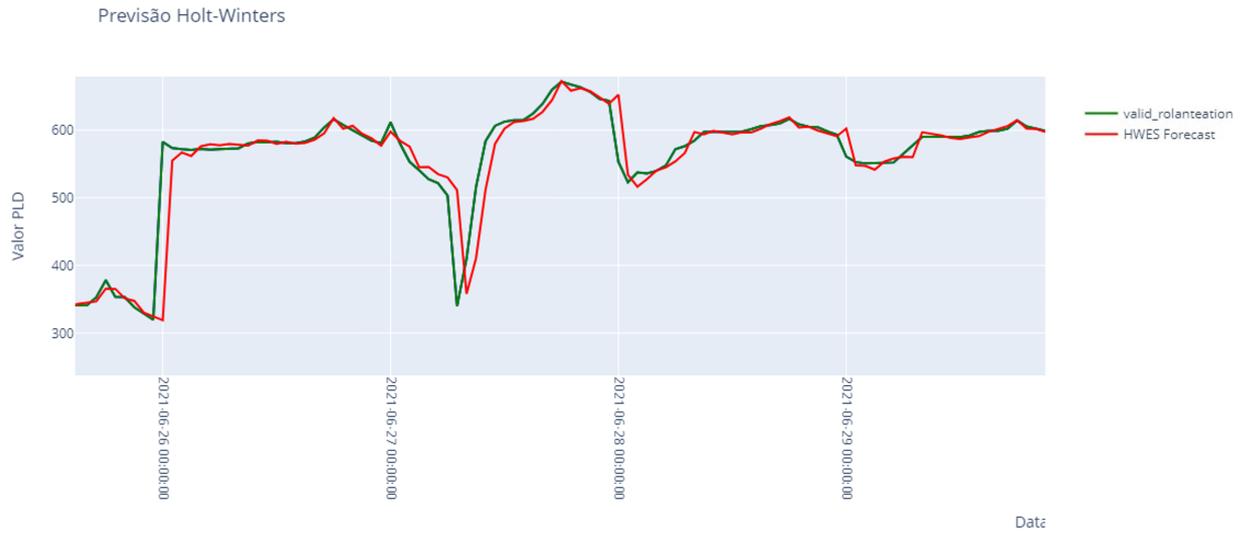
Pelo fato do período da previsão ser longo, há uma dificuldade em distinguir a linha do gráfico do *forecast* com o do valor real, por conta disso nas Figuras 18, Figuras 19 e Figuras 20 temos algumas amostrar de períodos da previsão.

Figura 18 – Previsão Holt-Winters com rolamento de 10/06/2021 a 11/06/2021



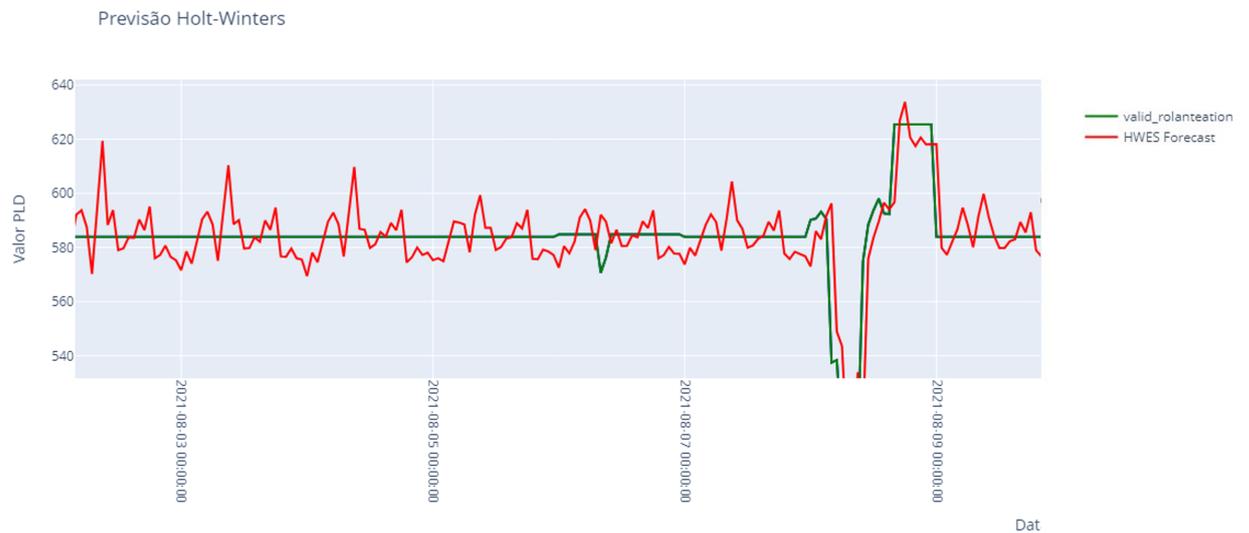
Fonte: Elaborado pelo Autor (2023)

Figura 19 – Previsão Holt-Winters com rolamento de 26/06/2021 a 29/06/2021



Fonte: Elaborado pelo Autor (2023)

Figura 20 – Previsão Holt-Winters com rolamento de 03/08/2021 a 09/08/2021



Fonte: Elaborado pelo Autor (2023)

Na Tabela 3 abaixo, temos o consolidado das quatro métricas utilizadas para avaliar os modelos.

Tabela 3 – Métricas de erro para o modelo Holt-Winters

Métrica de erro	Valor
MAE	7.031
MSE	287.189
RMSE	16.946
MAPE (%)	1.399

Fonte: Próprio autor (2023)

4.2.2 SARIMA

O método SARIMA foi aplicado utilizando o modelo `statsmodels.tsa.statespace.sarimax`, da biblioteca `Statsmodels`, e o processo de *Rolling forecast*. O código do SARIMA pode ser visto na Figura 21.

Figura 21 – Código SARIMA com rolamento

```
# SARIMA
from statsmodels.tsa.statespace.sarimax import SARIMAX

historico = train_sarima_rolante_single_ts.tolist()
teste = valid_sarima_rolante_single_ts.tolist()

previsoes = list()

# Previsão em rolagem
for t in range(len(teste)):
    # Defina o modelo
    modelo = SARIMAX(historico, order=(0,1,0), seasonal_order=(2,0,0,24))
    modelo_ajustado = modelo.fit(dispatch=0)

    yhat = modelo_ajustado.forecast()[0]
    previsoes.append(yhat)

    obs = teste[t]
    historico.append(obs)
    print(f'Previsto={yhat}, Esperado={obs}')
```

Fonte: Elaborado pelo Autor (2023)

Tendo o mesmo processo de *Rolling forecast* do modelo Holt-Winters, a previsão pelo modelo SARIMA se diferencia pelo fato de seus parâmetros não serem determinados automaticamente.

A princípio, o processo deve ser realizado de maneira manual, mas com a utilização da biblioteca `Pmdarima` e da função `auto_arima`, a determinação dos parâmetros $(p, d, q)(P, D, Q)$ pode ser feita de maneira automática.

A busca pelo melhor conjunto de parâmetros é realizada de forma eficiente através do método *Stepwise*. Durante esse processo, diversas combinações de $(p, d, q)(P, D, Q)$ são

comparadas pelo AIC ou Critério de informação de Akaike, em que este considera tanto a qualidade do ajuste do modelo aos dados quanto a complexidade do modelo. A partir disso o melhor modelo será aquele que obtiver o menor AIC.

Para executar esse processo, 45% dos dados de teste foram aplicados, resultando na identificação da melhor combinação de parâmetros: valores de (2,1,2)(2,0,0)24, com um AIC de 36095.892. Além disso todas as combinações de parâmetros podem ser vistos na Figura 22

Figura 22 – Combinações de parâmetros via Auto-ARIMA

```

Performing stepwise search to minimize aic
ARIMA(2,1,2)(1,0,1)[24] intercept : AIC=inf, Time=61.52 sec
ARIMA(0,1,0)(0,0,0)[24] intercept : AIC=36575.899, Time=0.10 sec
ARIMA(1,1,0)(1,0,0)[24] intercept : AIC=36280.121, Time=7.17 sec
ARIMA(0,1,1)(0,0,1)[24] intercept : AIC=36327.412, Time=9.16 sec
ARIMA(0,1,0)(0,0,0)[24] intercept : AIC=36573.913, Time=0.07 sec
ARIMA(1,1,0)(0,0,0)[24] intercept : AIC=36558.555, Time=0.19 sec
ARIMA(1,1,0)(2,0,0)[24] intercept : AIC=36242.429, Time=25.72 sec
ARIMA(1,1,0)(2,0,1)[24] intercept : AIC=inf, Time=54.22 sec
ARIMA(1,1,0)(1,0,1)[24] intercept : AIC=inf, Time=15.94 sec
ARIMA(0,1,0)(2,0,0)[24] intercept : AIC=36246.077, Time=21.10 sec
ARIMA(2,1,0)(2,0,0)[24] intercept : AIC=36239.361, Time=30.95 sec
ARIMA(2,1,0)(1,0,0)[24] intercept : AIC=36277.948, Time=11.16 sec
ARIMA(2,1,0)(2,0,1)[24] intercept : AIC=inf, Time=74.02 sec
ARIMA(2,1,0)(1,0,1)[24] intercept : AIC=inf, Time=25.94 sec
ARIMA(3,1,0)(2,0,0)[24] intercept : AIC=36239.875, Time=34.61 sec
ARIMA(2,1,1)(2,0,0)[24] intercept : AIC=36113.328, Time=118.84 sec
ARIMA(2,1,1)(1,0,0)[24] intercept : AIC=36148.915, Time=39.66 sec
ARIMA(2,1,1)(2,0,1)[24] intercept : AIC=inf, Time=148.54 sec
ARIMA(2,1,1)(1,0,1)[24] intercept : AIC=inf, Time=61.03 sec
ARIMA(1,1,1)(2,0,0)[24] intercept : AIC=36241.552, Time=54.92 sec
ARIMA(3,1,1)(2,0,0)[24] intercept : AIC=36113.973, Time=108.98 sec
ARIMA(2,1,2)(2,0,0)[24] intercept : AIC=36100.167, Time=169.47 sec
ARIMA(2,1,2)(1,0,0)[24] intercept : AIC=36125.025, Time=61.57 sec
ARIMA(2,1,2)(2,0,1)[24] intercept : AIC=inf, Time=180.08 sec
ARIMA(1,1,2)(2,0,0)[24] intercept : AIC=inf, Time=118.03 sec
ARIMA(3,1,2)(2,0,0)[24] intercept : AIC=36111.428, Time=163.23 sec
ARIMA(2,1,3)(2,0,0)[24] intercept : AIC=inf, Time=163.13 sec
ARIMA(1,1,3)(2,0,0)[24] intercept : AIC=36115.055, Time=73.90 sec
ARIMA(3,1,3)(2,0,0)[24] intercept : AIC=inf, Time=191.32 sec
ARIMA(2,1,2)(2,0,0)[24] intercept : AIC=36095.892, Time=59.41 sec
ARIMA(2,1,2)(1,0,0)[24] intercept : AIC=36122.784, Time=19.93 sec
ARIMA(2,1,2)(2,0,1)[24] intercept : AIC=inf, Time=117.73 sec
ARIMA(2,1,2)(1,0,1)[24] intercept : AIC=inf, Time=39.01 sec
ARIMA(1,1,2)(2,0,0)[24] intercept : AIC=36112.526, Time=71.98 sec
ARIMA(2,1,1)(2,0,0)[24] intercept : AIC=36111.422, Time=35.80 sec
ARIMA(3,1,2)(2,0,0)[24] intercept : AIC=inf, Time=62.49 sec
ARIMA(2,1,3)(2,0,0)[24] intercept : AIC=inf, Time=63.21 sec
ARIMA(1,1,1)(2,0,0)[24] intercept : AIC=36239.556, Time=17.27 sec
ARIMA(1,1,3)(2,0,0)[24] intercept : AIC=36113.148, Time=25.29 sec
ARIMA(3,1,1)(2,0,0)[24] intercept : AIC=36112.062, Time=32.95 sec
ARIMA(3,1,3)(2,0,0)[24] intercept : AIC=inf, Time=75.39 sec

Best model: ARIMA(2,1,2)(2,0,0)[24]
Total fit time: 2645.157 seconds

```

Fonte: Elaborado pelo Autor (2023)

Na Tabela 5, abaixo, temos o consolidado dos seis parâmetros do modelo SARIMA além do período de sazonalidade.

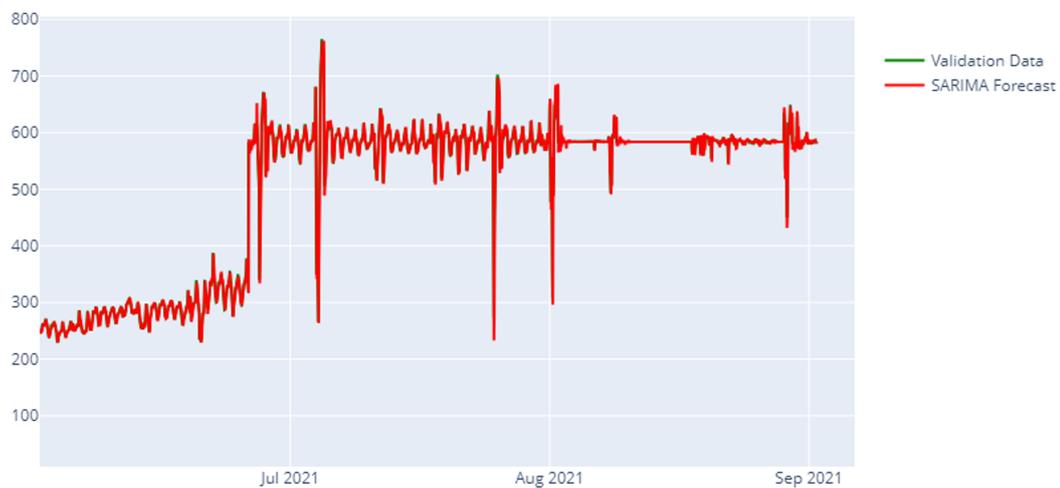
Tabela 4 – Melhores parâmetros para o modelo SARIMA

Parâmetro	p	d	q	P	D	Q	s
Valor	2	1	2	2	0	0	24

Fonte: Próprio autor (2023)

Com os parâmetros da Tabela 5, simulou-se o modelo SARIMA com rolamento, como é visto na Figura 23, Figura 24 e Figura 25

Figura 23 – Previsão SARIMA com rolamento



Fonte: Elaborado pelo Autor (2023)

Figura 24 – Previsão SARIMA com rolamento de 10/06/2021 a 13/06/2021



Fonte: Elaborado pelo Autor (2023)

Figura 25 – Previsão SARIMA com rolamento de 25/06/2021 a 26/06/2021



Fonte: Elaborado pelo Autor (2023)

As métricas de erro do SARIMA com rolamento podem ser vistas na Tabela 5.

Tabela 5 – Métricas de erro para o modelo Holt-Winters

Métrica de erro	Valor
MAE	5.796
MSE	272.737
RMSE	16.514
MAPE (%)	1.151

Fonte: Próprio autor (2023)

Para validar se o conjunto de parâmetros encontrado com o Auto-ARIMA é a melhor alternativa, com base nas métricas selecionadas, entre as opções apresentadas, outras duas simulações foram realizadas com valores encontrados pela função `auto_arima`. A tabela 6 a seguir compara as métricas dos três modelos de SARIMA com diferentes parâmetros.

Tabela 6 – Comparação das métricas de erro para os três modelos de SARIMA com rolamento

	(2,1,2)(2,0,0)	(1,1,0)(2,0,0)	(0,1,0)(2,0,0)
MAE	5.796	5.854	5.836
MSE	272.737	290.300	291.209
RMSE	16.514	17.038	17.064
MAPE	1.151	1.164	1.161

Fonte: Próprio autor (2023)

A partir da tabela 6, o modelo SARIMA com os parâmetros (2,1,2)(2,0,0) é a melhor combinação fornecida pela função Auto-ARIMA.

4.2.3 LSTM

A seleção apropriada de variáveis tem um papel crucial no desenvolvimento de modelos de redes neurais, sendo um dos aspectos principais na busca do melhor modelo e precisão. Optar por utilizar todas as variáveis disponíveis pode parecer o mais correto e intuitivo, mas tal decisão pode acarretar em um fenômeno conhecido como *overfitting*, comprometendo a eficácia do modelo.

O problema do *overfitting* ocorre quando o código se adapta excessivamente aos dados de treinamento, capturando não apenas padrões substanciais, mas também o ruído atrelado aos dados. Como forma de mitigar este problema, no modelo de *long short-term memory*, opta-se por realizar treinamentos com algumas combinações das três variáveis, como:

- a. PLD, CMO e Geração da energia em termelétrica;
- b. PLD e CMO;
- c. PLD e Geração da energia em termelétrica;
- d. CMO e Geração da energia em termelétrica;
- e. PLD.

Para a avaliação das combinações das variáveis e conseqüentemente da escolha de quais variáveis de entrada utilizar no modelo LSTM, foi utilizado as métricas de erro citadas na seção 2.5, que são o MAPE, MAE, MSE e RMSE. Também é válido ressaltar que para esta etapa foi utilizado um modelo de LSTM mais simplório, sem o processo de rolamento.

Com a análise das métricas de erro dos treinamentos do modelo LSTM com as diferentes combinações de variáveis, chegou-se à conclusão de que o melhor modelo é aquele que utiliza o PLD e o CMO como variáveis de entrada. Os resultados podem ser vistos na Tabela 7.

Tabela 7 – Resultados do Treinamento para Diferentes Combinações de Variáveis

	MAE	MSE	RMSE	MAPE (%)
PLD	6.814	203.177	14.254	3.421
PLD, CMO e Geração da energia	6.092	186.523	13.657	3.059
PLD e CMO	5.284	183.900	13.561	2.653
PLD e Geração da energia	8.333	209.024	14.458	4.184
CMO e Geração da energia	23.163	1284.100	35.834	11.629

Fonte: Próprio autor (2023)

Com as variáveis de entrada definidas, o modelo LSTM com rolamento foi treinado e implementado com os parâmetros da Tabela 8 e com o código da Figura 26, utilizando a função LSTM da biblioteca Tensorflow e Keras e o processo de *Rolling forecast*.

Tabela 8 – Parâmetros e Valores Utilizados no Modelo LSTM

Parâmetro	Valor
Unidades LSTM	40
<i>Input_shape</i> (LSTM)	(1)
Unidades Densa	1
<i>Look_Back</i>	1
<i>Epochs</i> (Treinamento Inicial)	10
<i>Epochs</i> (Validação)	1
<i>Batch_size</i>	10

Fonte: Próprio autor (2023)

Os valores apresentados na Tabela 8 foram obtidos por meio de experimento, onde várias implementações do modelo LSTM foram feitas, utilizando valores distintos para os parâmetros.

Figura 26 – Código LSTM com rolamento

```

# Construção e Treinamento do Modelo LSTM (Treinamento Inicial)
model = Sequential()
model.add(LSTM(40, input_shape=(look_back, len(cols_of_interest))))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')
model.fit(X_train, Y_train, epochs=10, batch_size=10, verbose=1)

rolling_predictions = []

for i in range(len(X_test)):
    # Fazendo a previsão para a próxima observação
    prediction = model.predict(X_test[i].reshape(1, look_back, len(cols_of_interest)))
    prediction_inv = scaler_target.inverse_transform(prediction) # desnormalizando a previsão

    # Adicionando a previsão à lista rolling_predictions
    rolling_predictions.append(prediction_inv[0, 0])

    # Obtendo o valor real e garantindo que actual_value é unidimensional
    actual_value = Y_test[i]

    # Adicionando a nova observação aos dados de treinamento
    new_X_train = np.append(X_train, X_test[i].reshape(1, look_back, len(cols_of_interest)), axis=0)

    # Garantindo que Y_train e actual_value têm as mesmas dimensões antes da concatenação
    new_Y_train = np.append(Y_train, [actual_value], axis=0) # note o [actual_value] para manter as dimensões consistentes

    # Retreinando o modelo com os dados atualizados
    model.fit(new_X_train, new_Y_train, epochs=1, batch_size=10, verbose=0)

```

Fonte: Elaborado pelo Autor (2023)

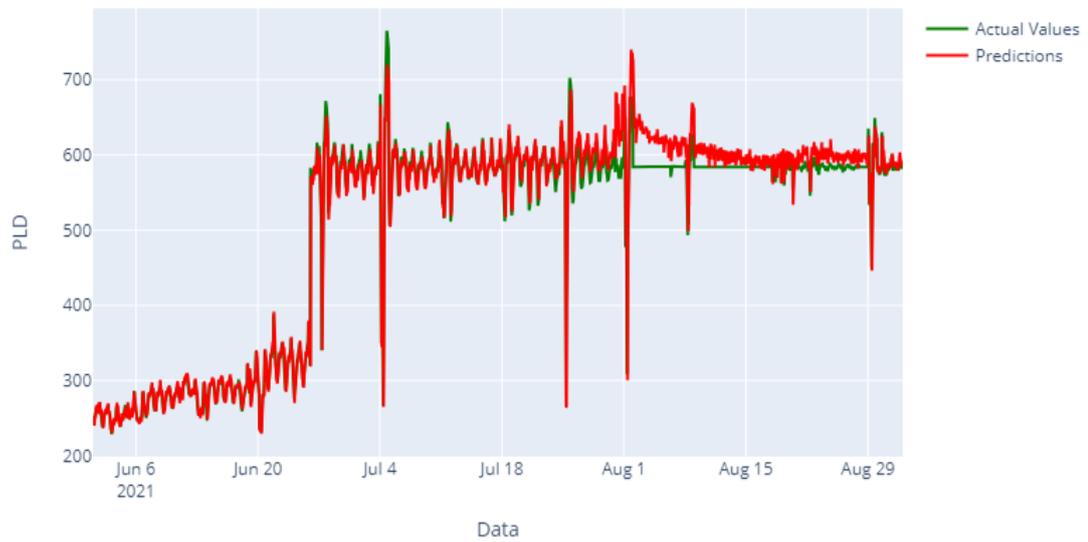
Com a aplicação do modelo *long short-term memory* os resultados obtidos podem ser vistos na Tabela 9, na Figura 27, na Figura 28 e na Figura 29.

Tabela 9 – Métricas de erro para o modelo LSTM

Métrica de erro	Valor
MAE	10.948
MSE	383.658
RMSE	19.587
MAPE (%)	2.174

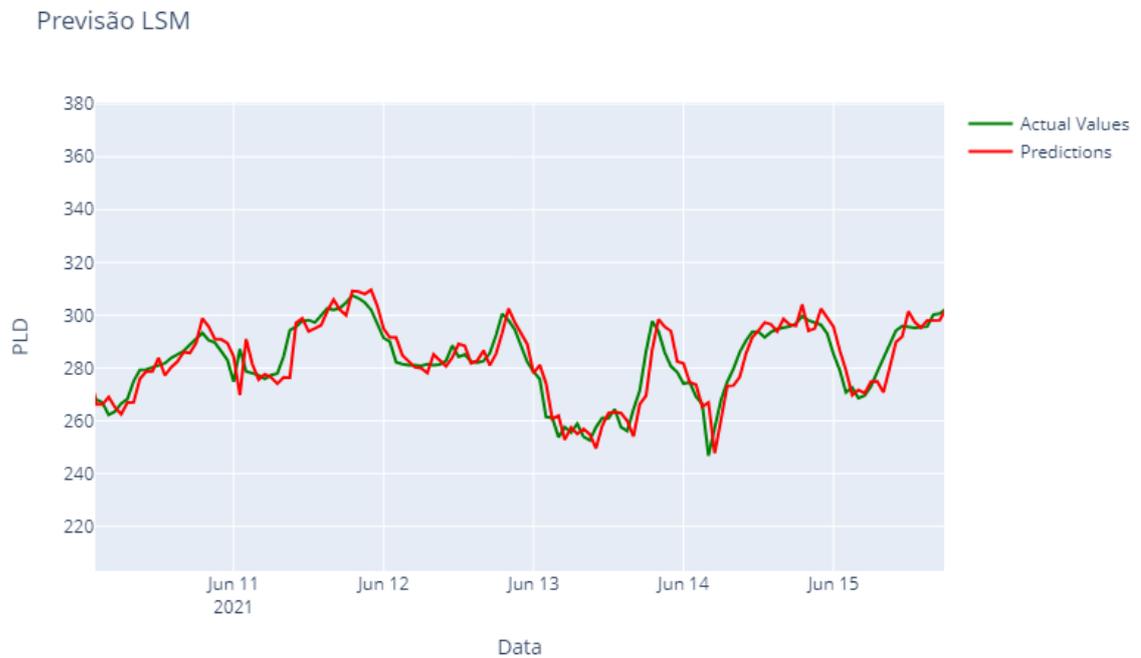
Fonte: Próprio autor (2023)

Figura 27 – Previsão LSTM com rolamento



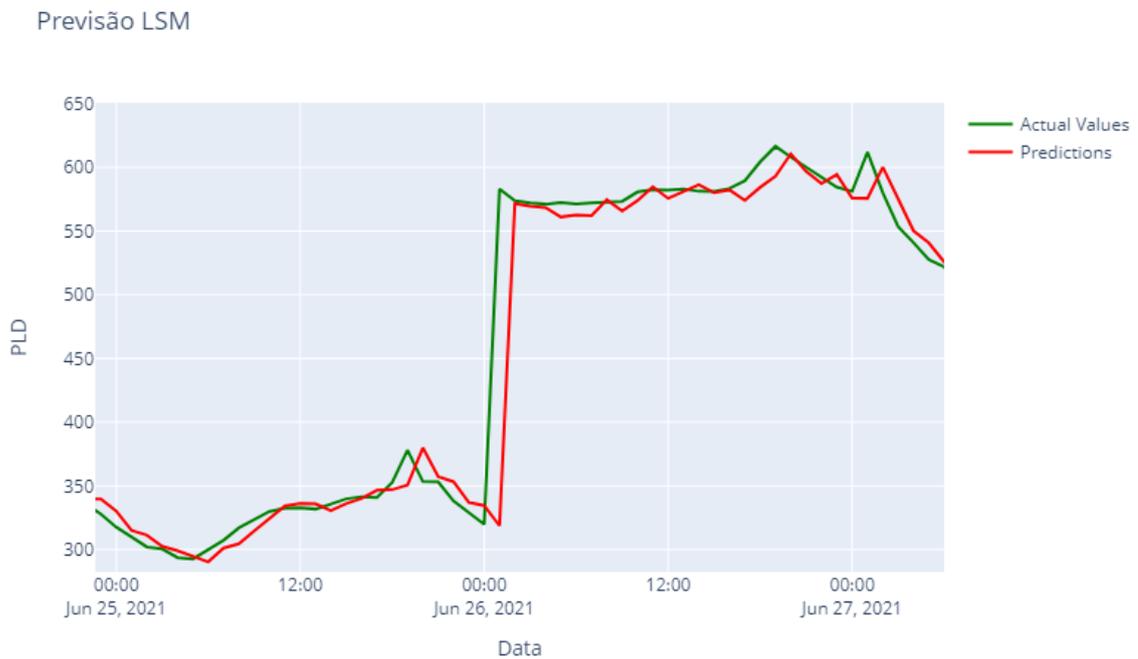
Fonte: Elaborado pelo Autor (2023)

Figura 28 – Previsão LSTM com rolamento de 11/06/2021 a 14/06/2021



Fonte: Elaborado pelo Autor (2023)

Figura 29 – Previsão LSTM com rolamento de 25/06/2021 a 27/06/2021



Fonte: Elaborado pelo Autor (2023)

4.3 DISCUSSÃO DOS RESULTADOS

Considerando as previsões efetuadas e os erros calculados na seção 4.2, pode-se comparar os resultados alcançados dos três modelos utilizados. A Tabela 10 demonstra os valores do MAE, MSE, RMSE e MAPE de cada modelo.

Tabela 10 – Comparação do modelos

	MAE	MSE	RMSE	MAPE (%)
Holt-Winters	7.031	287.189	16.946	1.399
SARIMA	5.796	272.737	16.514	1.151
LSTM	10.948	383.658	19.587	2.174

Fonte: Próprio autor (2023)

Quando analisa-se apenas os valores da Tabela 10, é possível perceber que o modelo SARIMA é aquele que apresenta os melhores resultados em todas as métricas utilizadas.

Ainda a respeito dos resultados, chama a atenção o fato do modelo LSTM ter apresentado o pior resultado entre todos os modelos analisados, mesmo sendo uma arquitetura robusta e sofisticada para tarefas que envolvem séries temporais.

O desempenho inferior pode ser atribuído a diversos fatores, como a metodologia utilizada para a seleção de hiperparâmetros e a própria complexidade do modelo.

A escolha dos hiperparâmetros foi realizada através de um método de tentativa e erro. Esse método, mesmo sendo comum, pode não ter sido o mais eficiente para a otimização do modelo, o que resultou na seleção de parâmetros que, embora fossem os melhores dentre os testados, não eram os ideais para o problema abordado neste trabalho.

Ao contrário do modo em que os parâmetros do LSTM foram escolhidos, nos modelos Holt-Winters e SARIMA, a seleção dos parâmetros foi feita de maneira mais assertiva, utilizando de funções presentes nas bibliotecas Statsmodels e Pmdarima, o que pode ter gerado melhores previsões a esses dois modelos.

A respeito da complexidade do modelo, o LSTM é um tipo de rede neural que tende a se sair melhor com sequenciais de grande volume e dados mais complexos, aonde padrões temporais de longo prazo precisam ser capturados. No entanto, se o *dataset* não é suficientemente complexo ou grande, como é o caso do utilizado neste projeto, o modelo de *long short-term memory* pode ser demais, levando até mesmo a um *overfitting*.

Apesar do modelo SARIMA ter sido o melhor entre o LSTM e o Holt-Winters em termos de acurácia da previsão, é importante mencionar o custo computacional associado ao seu processamento. Por ser um modelo estatístico robusto e com uma variedade grande de parâmetros, o SARIMA exige de mais recursos computacionais durante o processo de ajuste e validação, ainda mais quando há um *rolling forecast* atrelado ao modelo. Esta necessidade se reflete em um gasto maior de tempo e poder de processamento, tornando-o potencialmente menos eficiente quando é necessária uma rápida re-calibração do modelo, como no mercado de compra e venda de energia, ou em ambientes com recursos limitados, como é o caso deste trabalho. Na tabela 11 tem-se o tempo de processamento de cada um dos três modelos.

Tabela 11 – Comparação do tempo de processamento do modelos

Tempo de processamento	
Holt-Winters	8 minutos
SARIMA	9 horas
LSTM	1 hora

Fonte: Próprio autor (2023)

Vale ressaltar, ainda, que todos os três modelos apresentaram métricas de erro relativamente baixas quando analisada a variação máxima de 536,41 que o Preço de Liquidação das Diferenças teve, apontando um nível satisfatório na precisão das previsões.

Por fim, ainda se tratando dos resultados, é de extremo interesse fazer a comparação dos resultados obtidos neste projeto com o de trabalhos similares. Levando isso em

consideração, dois trabalhos foram utilizados: o de Lopes *et al.* (2022) e de Cardoso *et al.* (2021).

Lopes *et al.* (2022) utilizou quatro modelos diferentes de machine learning na previsão, de 7 dias à frente, do PLD, onde estes foram otimizados através da função gridsearch. Tais modelos obtiveram valores de MAPE relativamente elevados, com o modelo RNA apresentando o melhor resultado (24,70%). Em contraste, os modelos LSTM, SARIMA e Holt-Winters, aplicados neste trabalho, apresentam um melhor desempenho.

Cardoso *et al.* (2021), por sua vez, empregou diferentes modelos para a previsão do PLD de 15 dias à frente, mas não alcançou a precisão observada no estudo em análise. A falta de técnicas como o rolling forecast, também ocorridas no trabalho de Lopes, e a negligência da sazonalidade nos dados de entrada, parecem ter comprometido a eficácia dos modelos de Cardoso *et al.* (2021).

Ainda a respeito da comparação dos resultados deste trabalho com os de Lopes *et al.* (2022) e Cardoso *et al.* (2021), é importante salientar que como a previsão de ambos os trabalhos são de 7 e 15 dias à frente, respectivamente, é esperado que o presente trabalho obtenha valores de erros menores, o que de fato ocorre, uma vez que as previsões aqui realizadas foram feitas para 1 dia a frente.

5 CONCLUSÃO

O trabalho em questão teve como objetivo avaliar a acurácia de diferentes modelos de séries temporais na previsão do Preço da Liquidação das Diferenças de energia. Para realizar o trabalho foi utilizado as etapas metodológicas discutidas e abordadas na seção 3.2 e na Figura 8.

Com a etapa inicial, de revisão bibliográfica, buscou-se entender conceitos e estruturação do mercado de energia elétrica brasileiro, modelos matemáticos, modelos de *machine learning*, métricas de avaliação, além de entender quais variáveis podem influenciar no valor do PLD. Com a finalização do capítulo 2, o 1º objetivo específico do trabalho, identificar as variáveis que influenciam o PLD com base na literatura em questão, foi alcançado, como apresentado na Tabela 1 da seção 2.1.6.

O segundo objetivo, quantificar a influência das variáveis utilizadas na formação do PLD, foi contemplado com a realização das etapas 2, 3 e 4. A segunda etapa do projeto foca-se na coleta de dados fundamentais para a análise PLD, de 1º de julho de 2020 a 31 de agosto de 2021, descartando os dados de 2022 e 2023 por esses não possuírem variações significativas. Os dados da série histórica do PLD, produção de usinas termelétricas e Custo Marginal de Operação (CMO), foram coletados dos sites da Câmara de Comercialização de Energia Elétrica (CCEE) e do Operador Nacional do Sistema Elétrico (ONS), ambas fontes públicas. Na etapa 3, os dados foram pré-processados e ajustados, envolvendo transformação e agrupamento de valores. Com o uso da biblioteca Pandas, as informações foram consolidadas em um único *dataset*.

Realizou-se na etapa 4, uma análise mais aprofundada, utilizando as bibliotecas Tensorflow e Keras, para explorar e quantificar a influência do PLD, CMO e da Geração de energia em termelétricas, um modelo simplório de LSTM foi utilizado. Diferentes combinações dessas variáveis foram avaliadas usando métricas de erro como MAPE, MAE, MSE e RMSE. A simulação mostrou que a melhor performance foi alcançada utilizando PLD e CMO como variáveis de entrada. Com a conclusão desta etapa, o segundo objetivo específico do estudo foi alcançado.

O terceiro objetivo específico consistia em aplicar modelos de previsão, abordado no capítulo 4, utilizando os dados previamente estabelecidos nas etapas anteriores. Os modelos escolhidos para essa avaliação foram: Holt-Winters, SARIMA e LSTM, aplicando o método de *rolling forecast*.

De forma geral, os resultados obtidos neste trabalho foram bastante satisfatórios. Seus desempenhos foram comparados com base nas métricas MAE, MSE, RMSE e MAPE. O SARIMA superou os outros modelos em todas as métricas avaliadas. No entanto, possui um custo computacional mais alto, exigindo mais tempo e recursos de processamento. Isso pode ser uma desvantagem em cenários que requerem recalibrações rápidas do modelo.

O modelo LSTM, apesar de ser mais sofisticado e robusto para tarefas envolvendo

séries temporais, apresentou o pior desempenho. A eventual complexidade da definição dos hiperparâmetros dificulta seu ajuste e por mais que tenha ocorrido esforços para calibrar o modelo da melhor forma possível, não se pode descartar a possibilidade de que hajam hiperparâmetros mais adequados e que levariam a um desempenho melhor do modelo.

O trabalho em questão realizou uma comparação com trabalhos anteriores e obteve os resultados esperados. Foi constatado que os modelos utilizados neste trabalho superaram os desempenhos de trabalhos anteriores, este avanço é atribuído à adoção de uma janela de previsão menor. Com a comparação dos resultados obtidos o quarto e último objetivo específico, deste trabalho, foi concluído.

Acerca da discussão das sugestões de trabalhos futuros, voltados para a previsão, a exploração de diferentes técnicas e modelos é essencial para otimizar a previsão do PLD. A adoção do *grid search* na parametrização do LSTM poderia ser uma excelente estratégia, permitindo a determinação de configurações que possam produzir melhores resultados de previsão. Além disso, considera-se relevante testar o modelo SARIMAX, dado que este permite incorporar mais de uma variável de entrada. A capacidade de integrar diversas variáveis permite que o modelo seja mais adaptativo e receptivo às nuances e complexidades do PLD, potencialmente melhorando a qualidade e a precisão das previsões realizadas.

REFERÊNCIAS

- ABRACEEL. **Visão geral do Setor Elétrico Brasileiro**. [S.l.]. Acessado em: 12 jul. 22. Disponível em: https://www.abraceel.com.br/archives/files/Abraceel_Cartilha_MercadoLivre_V9.pdf.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **A ANEEL**. [S.l.]. Acessado em: 10 jul. 22. Disponível em: <https://www.gov.br/aneel/pt-br/aceso-a-informacao/institucional/a-aneel>.
- ANTONANZAS, Javier *et al.* Review of photovoltaic power forecasting. **Solar energy**, Elsevier, v. 136, p. 78–111, 2016.
- BELENTANI, Yuri. **Previsão do Preço de Energia no Mercado de Curto Prazo: Uma análise Combinada de Séries Temporais e Redes Neurais Artificiais**. 2023. Tese (Doutorado) – Universidade de São Paulo.
- BOX, George EP *et al.* **Time series analysis: forecasting and control**. [S.l.]: John Wiley & Sons, 2015.
- BRASIL. Lei nº 9.478, de 6 de agosto de 1997. **Casa Civil - Subchefia para Assuntos Jurídicos, Brasília, DF, 1997**.
- CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **O que fazemos: Com quem se relaciona**. [S.l.]. Acessado em: 10 jul. 22. Disponível em: <https://www.ccee.org.br>.
- _____. **Painel de Preços**. [S.l.]. Acessado em: 30 jul. 22. Disponível em: <https://www.ccee.org.br/web/guest/precos/painel-precos>.
- CAPELETTI, Marcelo. Análise da implementação do preço de liquidação das diferenças (PLD) horário no Brasil e a relação com variáveis de entrada do modelo de cálculo no horizonte de curto prazo. Universidade Federal de Santa Maria, 2019.
- CARDOSO, Manoella Schweitzer *et al.* Proposta de um modelo de previsão para o Preço de Liquidação das Diferenças Horário visando amparar o agendamento de manutenção em usinas eólicas. Florianópolis, SC, 2021.
- CENTRO DE PESQUISA DE ENERGIA ELÉTRICA. **Modelo de Despacho Hidrotérmico**. [S.l.]. Acessado em: 10 jul. 22. Disponível em: <https://www.cepel.br>.
- COMERC. **A chegada do PLD Horário no mercado de energia**. [S.l.]. Acessado em: 30 jul. 22. Disponível em: <https://panorama.comerc.com.br/a-chegada-do-pld-horario-no-mercado-de-energia>.

COMITÊ DE MONITORAMENTO DO SETOR ELÉTRICO. **Comitê de Monitoramento do Setor Elétrico**. [S.l.]. Acessado em: 09 jul. 22. Disponível em: <https://www.gov.br/mme/pt-br/assuntos/conselhos-e-comites/cmse>.

DEEPLARNINGBOOK. **Arquitetura de redes neurais: Long Short-Term Memory**. Acessado em: 10 out. 2023. 2023. Disponível em: <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/>.

EMPRESA DE PESQUISA ENERGÉTICA. **Empresa de Pesquisa Energética**. [S.l.]. Acessado em: 09 jul. 22. Disponível em: <https://www.epe.gov.br/pt/a-epe/o-que-fazemos>.

ENERGES. **DIFERENÇA ENTRE ACR E ACL**. [S.l.]. Acessado em: 14 jul. 22. Disponível em: <https://energes.com.br/diferenca-entre-acr-e-acl/>.

FAVA, Vera Lúcia *et al.* Manual de econometria. **Vasconcelos, MAS; Alves, D.** São Paulo: Editora Atlas, 2000.

FORTUNATO, Luiz Alberto M *et al.* Introdução ao planejamento da expansão e operação de sistemas de produção de energia elétrica. **Niterói, Universidade Federal Fluminense, EDUFF**, 1990.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. [S.l.]: "O'Reilly Media, Inc.", 2022.

GERS, Felix A; SCHMIDHUBER, Jürgen; CUMMINS, Fred. Learning to forget: Continual prediction with LSTM. **Neural computation**, MIT Press, v. 12, n. 10, p. 2451–2471, 2000.

GIL, Antonio Carlos *et al.* **Como elaborar projetos de pesquisa**. [S.l.]: Atlas São Paulo, 2002. v. 4.

GOMES, João Paulo Pombeiro; VIEIRA, Marcelo Milano Falcão. O campo da energia elétrica no Brasil de 1880 a 2002. **Revista de Administração Pública**, SciELO Brasil, v. 43, p. 295–321, 2009.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>.

HENNING, E; ALVES, CC; KONRATH, AC. Previsão de vendas de rodízios para móveis em uma empresa de médio porte. *In: ICPR AMERICAS-5th Americas International Conference on Production Research*, Bogotá, Colômbia, 2010. Proceedings... Bogotá. [S.l.: s.n.], 2010.

HOCHREITER, Sepp. Untersuchungen zu dynamischen neuronalen Netzen. **Diploma, Technische Universität München**, v. 91, n. 1, p. 31, 1991.

HOCHREITER, Sepp; BENGIO, Yoshua *et al.* **Gradient flow in recurrent nets: the difficulty of learning long-term dependencies**. [S.l.]: A field guide to dynamical recurrent neural networks. IEEE Press In, 2001.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, MIT press, v. 9, n. 8, p. 1735–1780, 1997.

HYNDMAN, Rob; KOEHLER, Anne B *et al.* **Forecasting with exponential smoothing: the state space approach**. [S.l.]: Springer Science & Business Media, 2008.

HYNDMAN, Rob J; ATHANASOPOULOS, George. **Forecasting: principles and practice**. [S.l.]: OTexts, 2018.

HYNDMAN, Rob J; KOEHLER, Anne B. Another look at measures of forecast accuracy. **International journal of forecasting**, Elsevier, v. 22, n. 4, p. 679–688, 2006.

LABORATÓRIO DE TECNOLOGIA DA INFORMAÇÃO E MÍDIAS EDUCACIONAIS DA UNIVERSIDADE FEDERAL DE GOIÁS. **Visão geral do Setor Elétrico Brasileiro**. [S.l.]. Acessado em: 10 jul. 22. Disponível em: http://www.labtime.ufg.br/modulos/aneel/mod1_uni2_sl7.html.

LAGASSE, William. Previsão do comportamento do preço de liquidação das diferenças (PLD) com ferramentas estatísticas, 2020.

_____. _____. 2020.

LOPES, Gustavo Henrique Angeoleti *et al.* Predição do Preço de Liquidação das Diferenças do Submercado Sul a partir de variáveis hidrológicas. Florianópolis, SC, 2022.

MAKRIDAKIS, Spyros. Accuracy measures: theoretical and practical concerns. **International journal of forecasting**, Elsevier, v. 9, n. 4, p. 527–529, 1993.

MEDSKER, Larry R; JAIN, LC. Recurrent neural networks. **Design and Applications**, v. 5, n. 64-67, p. 2, 2001.

MINISTÉRIO DE MINAS E ENERGIA. **Ministério de Minas e Energia - MME**. [S.l.]. Acessado em: 09 jul. 22. Disponível em: <https://dados.gov.br/organization/about/ministerio-de-minas-e-energia-mme>.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. Análise de séries temporais, 2022.

ODSC. Understanding the Mechanism and Types of Recurring Neural Networks, 2023. Acessado em: 09 out. 23. Disponível em: <https://opendatascience.com/understanding-the-mechanism-and-types-of-recurring-neural-networks/>.

OMAR, MS; KAWAMUKAI, H. **Prediction of NDVI using the Holt-Winters model in high and low vegetation regions: A case study of East Africa.** *Scientific African*, **14**, e01020. [S.l.: s.n.], 2021.

ONS. **Dados Abertos ONS.** [S.l.: s.n.], 2022. Acessado em: 30 de julho, 2022. Disponível em: <https://dados.ons.org.br/>.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **MAPA DINÂMICO DO SIN.** [S.l.]. Acessado em: 10 jul. 22. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/mapas>.

_____. **MAPA SIN Projeção 2024.** [S.l.]. Acessado em: 10 jul. 22. Disponível em: http://www.ons.org.br/PublishingImages/paginas/Setembro2019_Mapa.

_____. **O que é ONS.** [S.l.]. Acessado em: 13 jul. 22. Disponível em: <http://www.ons.org.br/paginas/sobre-o-ons/o-que-e-ons>.

PASCANU, Razvan; MIKOLOV, Tomas; BENGIO, Yoshua. On the difficulty of training recurrent neural networks. *In: PMLR. INTERNATIONAL conference on machine learning.* [S.l.: s.n.], 2013. P. 1310–1318.

PELLEGRINI, FR; FOGLIATTO, FS. Metodologia para Implantação de Sistemas de Previsão de Demanda–técnicas e estudo de caso. **Anais do XXI ENEGEP–Encontro Nacional de Engenharia de Produção–CD-ROM.** Salvador, 2001.

RUMELHART, David E; HINTON, Geoffrey E; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group UK London, v. 323, n. 6088, p. 533–536, 1986.

SHERSTINSKY, Alex. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. **Physica D: Nonlinear Phenomena**, Elsevier, v. 404, p. 132306, 2020.

SICARI, Luiz Felipe. Ambientes de contratação de energia mercado livre x mercado cativo. Universidade Federal de Uberlândia, 2021.

SILVA, Christiano Vieira da. Contratação de energia elétrica: aspectos regulatórios e econômicos. **CEP**, v. 70830, p. 030, 2011.

SOUZA MENDONÇA, Anny Key de; SILVA, Silvio Aparecido da; BORNIA, Antonio Cezar. ANÁLISE DA PREVISÃO DE SÉRIES TEMPORAIS

ATRAVÉS DA MODELAGEM HOLT WINTERS PARA O PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS (PLD). **REVISTA DE EXTENSÃO E INICIAÇÃO CIENTÍFICA DA UNISOCIESC**, v. 9, n. 2, 2022.

VERISSIMO, Andrey Jonas *et al.* Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 8, n. 4, 2013.

WHEELWRIGHT, Steven; MAKRIDAKIS, Spyros; HYNDMAN, Rob J. **Forecasting: methods and applications**. [S.l.]: John Wiley & Sons, 1998.

WILLIAMS, Ronald J. **Complexity of exact gradient computation algorithms for recurrent neural networks**. [S.l.], 1989.

WILLMOTT, Cort J; MATSUURA, Kenji. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate research**, v. 30, n. 1, p. 79–82, 2005.

ZHANG, G Peter. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, Elsevier, v. 50, p. 159–175, 2003.