

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

ARIENE APARECIDA LOPES MACIEL

**INTRODUÇÃO À PREVISÃO DE CURTO PRAZO DA CARGA DE UM
SISTEMA ELÉTRICO DE POTÊNCIA USANDO DADOS HISTÓRICOS
DE CONSUMO E DA TEMPERATURA AMBIENTE**

FLORIANÓPOLIS, 2023.

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE ELETROTÉCNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

ARIENE APARECIDA LOPES MACIEL

**INTRODUÇÃO À PREVISÃO DE CURTO PRAZO DA CARGA DE UM
SISTEMA ELÉTRICO DE POTÊNCIA USANDO DADOS HISTÓRICOS
DE CONSUMO E DA TEMPERATURA AMBIENTE**

Trabalho de Conclusão de Curso submetido
ao Instituto Federal de Educação, Ciência e
Tecnologia de Santa Catarina como parte
dos requisitos para obtenção do título de
Engenheiro em Engenharia Elétrica.

Orientador:
Prof. Sergio Luciano Avila, Dr. Eng.

FLORIANÓPOLIS, 2023.

**INTRODUÇÃO À PREVISÃO DE CURTO PRAZO DA CARGA DE UM SISTEMA
ELÉTRICO DE POTÊNCIA USANDO DADOS HISTÓRICOS DE CONSUMO E DA
TEMPERATURA AMBIENTE**

ARIENE APARECIDA LOPES MACIEL


Este trabalho foi julgado adequado para obtenção do título de Engenheiro(a) Eletricista e aprovado na sua forma final pela banca examinadora do Curso de Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Florianópolis, 29 de junho, 2023.


Banca Examinadora:



Prof. Sérgio Luciano Ávila, Dr. Eng.



Prof. Everthon Taghori Sica, Dr. Eng.



Prof. Pedro César Cordeiro Vieira, Dr. Eng.

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus por me proporcionar saúde, sabedoria e força durante toda essa jornada acadêmica. “Regozijai-vos sempre. Orai sem cessar. Em tudo dai graças” (1 Tessalonicenses 5:16-18).

Agradeço a minha família, especialmente aos meus pais e irmãos, por seu apoio incondicional ao longo dessa jornada. Seu amor, encorajamento e compreensão foram essenciais para que eu pudesse alcançar este momento importante em minha vida.

Agradeço ao meu orientador, Sergio Luciano Avila, por sua disponibilidade e orientação ao longo do desenvolvimento deste trabalho. Sua expertise, paciência e orientações foram fundamentais.

Agradeço aos pesquisadores do Grupo de Pesquisa em Computação Científica para a Engenharia (PECCE), em especial à Greicili dos Santos Ferreira e ao Deilson Martins dos Santos, pela sua contribuição significativa neste trabalho. Sua expertise e *insights* foram extremamente importantes para o aprimoramento da minha pesquisa.

Agradeço a todo o corpo acadêmico de professores do Departamento Acadêmico de Eletrotécnica (DAE) por seu conhecimento transmitido ao longo da graduação. Seus ensinamentos e dedicação foram essenciais para a minha formação.

Por fim, expresso minha gratidão aos meus colegas de classe. Suas trocas de experiências, discussões e apoio mútuo ao longo do curso foram enriquecedores e motivadores. Juntos, enfrentamos desafios e celebramos conquistas, construindo laços de amizade.

A todos vocês, os meus sinceros agradecimentos!

RESUMO

A previsão de carga de curto prazo desempenha um papel fundamental no planejamento, operação e controle do sistema de energia, sendo amplamente utilizada por concessionárias, operadores de sistema, geradores e comerciantes de energia. No Brasil, o Operador Nacional do Sistema Elétrico (ONS) é o responsável pela realização das previsões oficiais. A principal contribuição deste trabalho de conclusão de curso de graduação em engenharia elétrica é a validação de uma metodologia para previsão da carga de energia elétrica de curto prazo – dia seguinte – tendo como premissa a correlação que existe entre o consumo de energia elétrica e a temperatura ambiente. Os principais conceitos relacionados à análise de séries temporais são discutidos, fornecendo a base teórica necessária para o desenvolvimento do trabalho. Redes Neurais Recorrentes (RNN) com estrutura LSTM (*Long Short-Term Memory*) é a matemática escolhida para realizar as previsões. A técnica será avaliada utilizando as métricas MAPE (*Mean Absolute Percentage Error*) e coeficiente de determinação (R^2). A biblioteca de código aberto *TensorFlow* será utilizada como plataforma para implementação da RNN. Os dados utilizados – todos públicos e de livre acesso – compreendem o período de 2014 a 2021, e incluem informações históricas de carga, temperatura e feriados nacionais. O estudo é específico ao Subsistema Sul do Sistema Interligado Nacional (SIN), por interesse da autora. Os resultados obtidos são apresentados e discutidos, demonstrando uma acurácia do modelo com 95% de acerto na previsão.

Palavras-chave: Consumo. Energia Elétrica. Temperatura. LSTM. Subsistema Sul.

ABSTRACT

Short-term load forecasting plays a fundamental role in the planning, operation, and control of the power system, and it has been used by utilities, system operators, generators, and energy traders. In Brazil, the National Electric System Operator (ONS) is responsible for making the official forecasts. The main contribution of this work for the conclusion of the undergraduate course in electrical engineering is the validation of a methodology for forecasting the short-term - day-ahead - electric power load, based on the premise that there is a correlation between electric power consumption and ambient temperature. The main concepts related to time series analysis are discussed, providing the theoretical basis necessary for the development of the work. Recurrent Neural Networks (RNN) with LSTM (Long Short-Term Memory) structure is the mathematics chosen to perform the predictions. The technique is evaluated using the metrics MAPE (Mean Absolute Percentage Error) and coefficient of determination (R^2). The open-source TensorFlow library is the platform for the implementation of the RNN. The data used - all public and freely accessible - comprises the period from 2014 to 2021, and includes historical information on load, temperature, and national holidays. The study is specific to the Southern Subsystem of the National Interconnected System (SIN), an author choice. The results have 95% accuracy in the forecast.

Keywords: Consumption. Electrical Energy. Temperature. LSTM. Southern Subsystem.

LISTA DE FIGURAS

Figura 1 - Diferença entre sazonalidade e ciclo.	23
Figura 2 - Representação de um neurônio biológico.	27
Figura 3 - Neurônio artificial	27
Figura 4 - Principais funções de ativação para as RNA.	28
Figura 5 - Representação de uma Rede <i>Feedforward</i> de Camada simples.....	30
Figura 6 - Representação de uma Rede <i>Feedforward</i> de Camada Múltiplas.....	31
Figura 7 - Exemplos de conexões de uma rede recorrente.....	32
Figura 8 - Arquitetura de uma LSTM.	33
Figura 9 - Visão Geral do Processo da Consolidação da Carga Diária.	41
Figura 10 - Etapas da metodologia.	46
Figura 11 - Serie Temporal da Carga e Temperatura ao Longo dos Anos.....	54
Figura 12 - Variação Média da Carga e da Temperatura Mensal ao Longo do Tempo.....	55
Figura 13 - Tendência de Crescimento.	55
Figura 14 - Carga Média Histórica Anual.	56
Figura 15 - Carga Média x Temperatura Média - Mensal.....	57
Figura 16 - Carga Média Histórica Semanal.....	58
Figura 17 - Carga Média Horária.....	58
Figura 19- Previsão de carga diária Segunda-Feira - 01 de junho de 2020.	62
Figura 20 - Previsão de carga diária Domingo – 20 de setembro de 2020.	62
Figura 21 - Previsão de carga diária Feriado Nacional – 25 de dezembro de 2021.	63
Figura 22 - Previsão de carga diária dia mais quente dos dados testes – 25 de novembro de 2020.	63
Figura 23 - <i>Loss function</i> arquitetura 1-4.....	64
Figura 24 - <i>Loss function</i> arquitetura 5-8.....	65
Figura 25 - <i>Loss function</i> arquitetura 9-12.....	65
Figura 26 - <i>Loss function</i> arquitetura 13-16.....	66
Figura 27 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo subajustado.	67
Figura 28 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo sobreajustado.	67
Figura 29 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo <i>good fit</i>	68

Figura 30 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando conjunto de dados de treinamento não representativo.....	69
Figura 31 - Portal SINtegre ONS.....	93

LISTA DE TABELAS

Tabela 1 - Parâmetros adotados para o modelo LSTM/RNN.	50
Tabela 2 - Valores de Correlação de <i>Pearson</i> e <i>Spearman</i> entre Variáveis.	59
Tabela 3 - Resultados obtidos para as 16 configurações de arquiteturas da RNN- LSTM para a previsão da carga diária - Subsistema Sul.	61

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	<i>Autorregressive Integrated Moving Average</i>
ANACE	Associação Nacional dos Consumidores de Energia
ANNSTLF	<i>Artificial Neural Network Short-Term Load Forecaster</i>
ART	Teoria de Ressonância Adaptativa (<i>Adaptive Resonance Theory</i>)
ARTMAP	<i>Adaptive Resonance Theory – Supervised Predictive Mapping</i>
B(R)LF	<i>Base or Regular Load Forecaster</i>
C(D)LF	<i>Change or Delta Load Forecaster</i>
CEPEL	Centro de Pesquisas de Energia Elétrica
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CS	<i>Cuckoo Search</i>
DLL	<i>Dynamic-link library</i>
EPE	Empresa de Pesquisa Energética
EPRI	<i>Electric Power Research Institute</i>
FARIMA	<i>Fractional Seasonal Autoregressive Integrated Moving Average</i>
IA	Inteligência Artificial
IC	Inteligência Computacional
LABSMART	Laboratório de Redes Elétricas Inteligentes
LRD	<i>Long-range dependence</i>
LSTM	<i>Long Short Term Memory</i>
MAE	<i>Mean absolute error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
Nftool	<i>Toolbox Neural net fitting tool</i>
ONS	Operador Nacional do Sistema Elétrico
PDE	Programação Diária da Operação Eletroenergética
PECCE	Pesquisa em Computação Científica para a Engenharia
PIB	Produto Interno Bruto
PSPL	<i>Puget Soun Power e Light Co</i>
REGER	Rede de Gerenciamento de Energia
RLS	<i>Recursive Least Squares</i>
RNAs	Redes Neurais Artificiais
RNN	Redes Neurais Recorrentes

SAGIC	Sistema de Apuração da Geração, Intercâmbio e Carga
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
SEB	Sistema Elétrico Brasileiro
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
	Sistema de Previsão de Carga para os Estudos Elétricos e
SPCEE	Energéticos
SVR	<i>Support Vector Regression</i>
VBA	<i>Visual Basic for Application</i>

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Justificativa	11
1.2	Definição do Problema	12
1.2.1	Premissas e contra escopo	13
1.3	Objetivo Geral.....	13
1.4	Objetivos Específicos.....	14
1.5	Estrutura do Trabalho.....	14
2	ESTADO DA ARTE	15
2.1	Previsão de carga	15
3	SÉRIES TEMPORAIS.....	22
4	INTELIGÊNCIA COMPUTACIONAL	25
4.1	Redes neurais artificiais	26
4.1.1	Neurônio Artificial	26
4.1.2	Arquitetura de uma Rede Neural.....	29
4.1.2.1	<i>Feedforward de camada simples e múltiplas camadas.....</i>	<i>29</i>
4.1.2.2	<i>Redes neurais recorrentes</i>	<i>31</i>
4.1.3	Processo de Aprendizagem de uma Rede Neural Artificial.....	34
5	PREVISÃO DE CARGA PARA A PROGRAMAÇÃO DIÁRIA ELETROENERGÉTICA DO SEB PELO ONS	38
5.1	Processo da previsão da carga diária.....	40
5.1.1	Leitura e gravação dos dados de cargas e temperaturas	41
5.1.2	Tratamento de <i>missings</i> e <i>outliers</i>	42
5.1.3	Modelos de previsão	42
5.1.4	Tomada de decisão.....	44
6	DESCRIÇÃO DA METODOLOGIA	46
6.1	Dados históricos e calendário civil	46
6.2	Calibração do modelo neural	47
6.3	Métricas de Avaliação.....	50
7	ESTUDO DE CASO	52
7.1	Dados Históricos - Obtenção, Exploração e Processamento dos Dados	53
7.2	Resultados e discursões	60
8	CONCLUSÃO FINAL	70
8.1	Sugestões para trabalhos futuros	71
	REFERÊNCIAS.....	73
	Anexo 1 86	
	Anexo A – Código	87
	Anexo B – Dados de entrada	92

1 INTRODUÇÃO

Entende-se previsão como uma estimativa futura. Os modelos de previsão são comumente utilizados em diversos setores da economia, podendo-se citar por exemplo: previsão de ações e índices de bolsas de valores, previsão de demanda no gerenciamento de estoques, monitoramento de transmissão de doenças, e a previsão do tempo (KUSTER; REZGUI; MOURSHED, 2017). Da mesma maneira, as previsões desempenham um papel crucial no segmento dos Sistemas Elétricos de Potência (SEP).

As previsões são muito utilizadas para estimar a demanda de energia elétrica, sendo essencial para a gestão de energia e programação de manutenção do sistema (BASSO, 2020). Previsões de demanda ajudam a evitar possíveis falhas do sistema, como o caso que ocorreu no ano de 2001. Naquele ano, o Brasil sofreu um forte desequilíbrio entre a oferta e demanda de energia elétrica, que ficou conhecida como a “crise do apagão”. Segundo a Associação Nacional dos Consumidores de Energia - ANACE (2022), pelo menos 53 milhões de brasileiros sofreram com transtornos e prejuízos. Normalmente grandes apagões normalmente ocorrem por falhas no sistema de transmissão (ANACE, 2022).

Diante do contexto exposto, este TCC propõe uma introdução ao tema, realizando a previsão de carga no cenário nacional utilizando redes neurais artificiais (RNA).

1.1 Justificativa

O setor de energia elétrica brasileiro passa por profundas mudanças no planejamento da operação e na comercialização de energia elétrica devido às alterações nas legislações e o uso de novas tecnologias. Pode-se citar por exemplo o desmembramento das atividades de geração, de transmissão, de distribuição e de compra e venda de energia elétrica - os chamados consumidores livres. Tais mudanças criam comportamentos diversos dos agentes envolvidos com o Sistema Interligado Nacional (SIN) (ONS, 2021a).

Dentre múltiplas implicações dessas mudanças, está a necessidade de melhor previsão de demanda por energia elétrica. Esta informação sempre foi importante para a programação da operação. Agora, passa a ser relevante também na comercialização de energia elétrica, em particular para o mercado livre. Uma tomada de decisão mais lucrativa de quando e por quanto será comprada ou vendida a energia passa por saber qual a quantidade e quando ela será necessária. Segundo McHugh, Coleman e Kerr (2021), modelos precisos de previsão são benéficos para os comerciantes de energia, pois estes possibilitam observar tendências dos preços de eletricidade e, com o tempo, podem levar a uma redução nos custos de comercialização.

Para orientar os agentes, o Operador Nacional do Sistema Elétrico (ONS) publica regularmente sumários, notas técnicas e boletins sobre previsão de carga, como por exemplo a “revisão quadrimestral das projeções da demanda de energia elétrica do SIN” (ONS, 2021b). De forma complementar, a Empresa de Pesquisa Energética (EPE) publica anualmente o “plano decenal de expansão de energia”, que é um documento informativo voltado para toda a sociedade, com uma indicação das perspectivas de expansão futura do setor de energia sob a ótica do Governo (EPE, 2021).

A obtenção e o armazenamento de dados confiáveis passaram a ser parte integrante do patrimônio das empresas. Um sistema eficiente de previsões de carga é um diferencial na mesa de negociações. Os agentes e o ONS vêm fazendo

investimentos para aperfeiçoar os seus sistemas de aquisição de dados e a transformação destes em informação útil para tomadas de decisão mais eficientes e lucrativas. Cita-se em específico o portal de dados abertos do ONS (ONS, 2021c).

1.2 Definição do Problema

O Sistema Elétrico de Potência (SEP) “é o conjunto de todas as instalações e equipamentos destinados à geração, transmissão e distribuição de energia elétrica” (BICHELS, 2018). Um bom funcionamento de um SEP é garantido com planejamento, operação e manutenção.

A previsão de carga é fundamental nos processos de planejamento e de operação do SEP (FERREIRA, 2020). Ela influencia a tomada de decisões no planejamento da expansão, fluxo de potência, operação econômica, análise e controle de segurança de sistema de energia elétrica (ZHOU; ZHOU; DENG, 2019).

A previsão de carga pode ser feita a curtíssimo, a curto, a médio e longo prazo. A diferença entre elas está no período de previsão. Baseado em Fernandes *et al.* (2021), este TCC opta pela seguinte denominação: para a previsão a curtíssimo prazo, a carga que será prevista é de alguns minutos até uma hora a frente; a de curto prazo prevê por uma faixa de 24 horas (dia seguinte) até uma semana a frente; já a previsão média prazo, o período estende-se a alguns meses; por fim, a de longo prazo o período interessado é superior a um ano.

Para obter um modelo de previsão de carga é preciso conhecer as características que influenciam o consumo de energia (BENDAOU; FARAH; BEN AHMED, 2022). Isto é, compreender fatores como temperatura, estações do ano, hábitos de consumo, entre outros, todos correlacionados diretamente.

Historicamente, veem sendo aplicados uma ampla variedade de métodos para a previsão da carga, como por exemplo: baseados em estatística (LEKSHMI; ADITHYA SUBRAMANYA, 2019), baseados em inteligência computacional (IC) (HU *et al.*, 2020), ou métodos híbridos onde há uma combinação de dois ou mais métodos (BASHARI; RAHIMI-KIAN, 2020). Recentemente, métodos híbridos têm ganhado destaque por atrelar os benefícios dos outros métodos. A ideia é juntar a experiência

dos especialistas aos dados históricos do sistema e, assim, extrair informações para tomadas de decisões mais eficientes (FERNANDES *et al.*, 2021).

Dentre dos métodos baseados em IC, destaca-se as Redes Neurais Artificiais (RNAs). As RNAs “são uma técnica de processamento baseada em sistemas nervosos biológicos tais como o cérebro humano” (GUIRELLI, 2006). As RNAs são modeladas para a solução de problemas usando dados históricos, por meio de um processo de aprendizagem, o qual pode ser orientado pela experiência de um especialista no problema.

Busca-se neste trabalho desenvolver um modelo de previsão de carga a curto prazo de um sistema elétrico de potência. Para tal, uma RNA será treinada para prever cargas horárias do dia seguinte com base na temperatura ambiente, informações do calendário civil e cargas históricas.

1.2.1 Premissas e contra escopo

As principais premissas e contra escopo estão listadas a seguir:

- a) são usados apenas dados históricos públicos e de livre acesso (ONS, 2023);
- b) é feito uso de bibliotecas *python* públicas e de livre acesso (PYTHON, 2023);
- c) as previsões realizadas têm fim acadêmico, tendo como objetivo maior o processo de aprendizagem da autora e dos discentes que vierem a ler este TCC nos temas relacionados;
- d) busca-se um alinhamento ao estado da arte e ao que vem sendo praticado pelas empresas do setor elétrico, mas simplificações são necessárias em função da maturidade e do tempo disponível para este TCC.

1.3 Objetivo Geral

Desenvolver um modelo de previsão de carga a curto prazo de um sistema elétrico de potência brasileiro, com acurácia acima dos 95%.

1.4 Objetivos Específicos

- a) estruturar banco de dados próprio, fazendo-se o uso de informações públicas;
- b) implementar uma rede neural capaz de prever a demanda de energia elétrica com horizonte de tempo diário;
- c) gerar e discutir cenários de previsão de carga.

1.5 Estrutura do Trabalho

Este TCC está organizado em sete capítulos. Iniciando por este capítulo introdutório, onde são apresentados os objetivos, justificativas e a problemática. O Capítulo 2 apresenta uma revisão bibliográfica com os conceitos básicos dos principais métodos utilizados na previsão de carga a curto prazo encontrados na literatura, apresentando suas vantagens e desvantagens considerando as características dos dados e do problema. No Capítulo 3, define-se as séries temporais e discute-se as características básicas das técnicas de análise. No Capítulo 4 são abordados os conceitos fundamentais das redes neurais, incluindo a arquitetura básica de uma rede neural e o processo de aprendizado dessas redes. O Capítulo 5 discute o processo de previsão de carga diária realizado pelo ONS para os subsistemas. São apresentadas as principais técnicas e métodos utilizados. A metodologia empregada para realizar a previsão de carga diária do subsistema Sul é detalhada no Capítulo 6. Ainda neste capítulo são definidos índices de desempenho do modelo. O Capítulo 7 aborda os procedimentos de obtenção, exploração e processamento dos dados de entrada necessários para o modelo de previsão. Nesse capítulo é discutida a importância da qualidade dos dados. Ainda são apresentados os resultados obtidos no modelo de previsão. Finalmente, o Capítulo 8 apresenta os resultados de previsão e as reflexões quanto a sua pertinência. Apresenta-se também discussão sobre as limitações do trabalho aqui desenvolvido e aponta-se oportunidades para trabalhos futuros.

2 ESTADO DA ARTE

As previsões de carga para um SEP podem ser feitas em diferentes períodos de tempo. A previsão de carga a curto prazo desempenha um papel importante pois auxilia na segurança e na estabilidade do sistema de energia, controla a geração de energia equilibrando a oferta e a demanda de eletricidade em tempo real (AOYANG *et al.*, 2021; LV *et al.*, 2020). Neste contexto, neste TCC optou-se por trabalhar com previsão de carga com um horizonte preditivo de 24 horas à frente (*day ahead*).

2.1 Previsão de carga

A eletricidade como um produto, em comparação com um produto material, tem características muito diferentes (ALMESHAEI; SOLTAN, 2011). Ela ainda não pode ser armazenada em grandes quantidades (QIUYU *et al.*, 2017), então deve ser gerada e utilizada assim que for demandada. Um dos principais objetivos estratégicos de empresas do setor elétrico é fornecer aos usuários finais eletricidade segura e estável. Assim, a precisão implica impactos significativos na economia (SINGH; HUSSAIN; BAZAZ, 2017).

Previsão de carga de eletricidade é volátil, subestimar ou superestimar pode causar problemas críticos (JHA *et al.*, 2021). Segundo Singh, Hussain e Bazaz (2017), a superestimação na previsão de carga pode levar ao aumento desnecessário da reserva e dos custos operacionais. Já a subestimação, pode causar uma falha no fornecimento de reserva de operação e estabilidade ao sistema, o que pode resultar em um colapso da rede do sistema elétrico de potência (KHWAJA *et al.*, 2017).

No que se refere a previsão de cargas elétricas, considera-se as cargas globais do sistema (JÚNIOR, 2020). Segundo o ONS (2016) a carga global é a geração bruta, na saída do gerador, injetada nos sistemas de transmissão e distribuição que supre a demanda das unidades consumidoras e as perdas internas das instalações de geração, transmissão e distribuição. Júnior (2020), define que as cargas globais são combinações de vários equipamentos e dispositivos que, quando em conjunto, modelam a carga. Já Ferreira (2020), diz que cargas globais compreendem a soma de todas as cargas individuais do sistema, em outras palavras,

todos os barramentos. “A previsão de carga de forma global pode ser vantajosa nas atividades estratégicas do SEPs, como despacho da energia gerada, compra de eletricidade, etc”.(FERREIRA, 2020). Este TCC utiliza a definição do ONS.

Conforme foi elucidado na definição do problema, variados métodos são utilizados para a previsão de carga a curto prazo, sendo os principais: métodos estatísticos, métodos baseados em IC e métodos híbridos.

Estudos sobre previsão de carga de curto prazo são desenvolvidas há algum tempo. Os primeiros estudos foram baseados na aritmética clássica, principalmente em modelos estatísticos (LI, 2021). Métodos estatísticos são técnicas nas quais há uma modelagem matemática da carga (JÚNIOR, 2020). Aplicam combinações matemáticas aos dados históricos das cargas (FERREIRA, 2020), para ajustar a tendência de variação dos dados de carga em relação ao tempo, usando a diferença entre as cargas reais e previstas para adequar os parâmetros do modelo (LUO; ZHANG; WANG, 2022).

Os métodos estatísticos de previsão podem ser divididos em métodos baseados em séries temporais e regressão (FERNANDES *et al.*, 2021). Xavier (2018) define que uma série temporal é um conjunto de observações, em função do tempo, de um modelo. O principal objetivo de uma série temporal é caracterizar um modelo que se adeque aos dados e assim realizar as previsões, o melhor modelo é aquele que minimiza os erros entre os valores estimados e os dados observados. Esta análise pode ser feita de duas formas: análise temporal (domínio do tempo); e análise espectral (domínio da frequência). Série de regressão é um modelo matemático que relaciona duas ou mais variáveis. Este modelo é uma equação que associa o que se deseja prever (variável dependente) com às preditoras (variáveis independentes) (CAMPOS; MARINHO 2019).

Dentre dos modelos estatísticos mais comuns, citados por diversos autores, são os modelos *Autorregressive Integrated Moving Average* (ARIMA), também conhecido como modelos *Box e Jenkins* (FERREIRA, 2020; LUO; ZHANG; WANG, 2022; TANG *et al.*, 2022; XAVIER, 2018; ZHANG *et al.*, 2018). Estes modelos são usados para modelar series temporais não estacionarias (XAVIER, 2018). Uma série temporal é não estacionaria quando suas características estatísticas médias, variância, autocorrelação, entre outras não são constantes ao longo do tempo.

Xavier (2018) realizou um estudo de caso no qual foi feita a previsão de carga da região Nordeste. Para tal, foi utilizado o modelo ARIMA sazonal também conhecido como SARIMA (*Seasonal Autoregressive Integrated Moving Average*). A metodologia utilizada foi embasada na análise das funções de autocorrelação e autocorrelação parcial da série temporal.

Wu *et al.* (2020) propôs um estudo que utiliza o modelo ARIMA com características fracionária, conhecido como FARIMA (*Fractional Seasonal Autoregressive Integrated Moving Average*), para a previsão de carga de curto prazo. O estudo foi baseado na dependência de longo alcance (LRD- *long-range dependence*). O modelo LRD é governado pelo expoente de Hurst, que mostra se o modelo exibe o LRD ou não. Em seguida, o estudo emprega o algoritmo *Cuckoo Search* (CS) baseado no ajuste dinâmico de dois parâmetros para otimização do modelo de previsão.

Cabe destacar que os métodos estatísticos apresentam resultados plausíveis apenas na resolução de problemas de previsão linear na série temporal, sendo que os padrões não lineares não podem ser ajustados de forma eficaz (LI, 2021; LUO; ZHANG; WANG, 2022). Devido à não linearidade e a natureza complexa dos conjuntos de dados na previsão de carga a curto prazo, Jha *et al.* (2021) afirma que as técnicas estatísticas, mesmo sendo utilizadas há muito tempo, podem ser ineficientes.

Diante das desvantagens dos modelos estatísticos, foram desenvolvidos modelos baseados em IC. Usualmente, IC é definido como um conjunto de metodologias e abordagens computacionais baseadas em dados (CHEN *et al.*, 2019). Tais metodologias podem ter características inspiradas no comportamento humano, como: raciocínio, dedução, aprendizado, evolução e adaptação (GOLDSCHMIDT, 2010).

Os modelos baseados em IC usam dados históricos, ou seja, não há necessidade de um modelamento matemático complexo (LUO; ZHANG; WANG, 2022). Uma das técnicas de IC que mais cresce no campo da previsão de séries temporais a curto prazo são as RNAs. As RNAs simulam o cérebro humano e podem produzir resultados satisfatórios para resolver problemas lineares e não lineares (LI, 2021). Além disso é possível realizar ajustes adaptativos, determinar modos de previsão e relações difusas (LUO; ZHANG; WANG, 2022).

O primeiro estudo utilizando RNA para previsão de carga a curto prazo foi proposto por Park *et al.* (1991). O algoritmo desenvolvido utiliza uma RNA em camadas, baseada no estudo publicado por Lapedes e Farber (1987 *apud* Park *et al.*, 1991). Para a obtenção da carga prevista, a RNA interpolou a carga e a temperatura em um conjunto de dados. A média de erros absolutos das previsões conseguida no teste para um horizonte de uma hora foram de 1,40% e para um horizonte de 24 horas 2,06%. Diante deste trabalho pioneiro, vários tipos de RNAs foram desenvolvidas para a solução do problema previsão de carga.

Como por exemplo, o estudo de Xavier (2018), citado anteriormente nos exemplos de previsão de carga com métodos estatísticos. No mesmo trabalho a autora desenvolveu a mesma previsão, desta vez utilizando RNA. Comparando os dois métodos, verificou-se que ambos apresentaram bons índices de desempenho, contudo as redes neurais artificiais apresentam algumas vantagens sobre o modelo ARIMA, como a possibilidade de incorporar variáveis de regressão ao modelo.

As RNA's também podem ser utilizadas no problema de previsão de carga elétrica multimodal, são as cargas que estão nos nós (barramento) do sistema. Alguns trabalhos foram desenvolvidos como o de Ferreira (2020), que desenvolveu rede neural ARTMAP (*Adaptive Resonance Theory – Supervised Predictive Mapping*) Euclidiana e Júnior (2020) que desenvolveu a rede neural ARTMAP *Fuzzy*. Ambas são fundamentadas na Teoria de Ressonância Adaptativa (ART). Contudo a primeira tem uma arquitetura neural baseada na distância euclidiana e a segunda tem características baseadas no dilema da estabilidade e plasticidade. Para avaliação das metodologias propostas nos dois estudos foi utilizado o erro percentual médio absoluto MAPE (*Mean Absolute Percentage Error*), os dados históricos de cargas elétricas utilizados foram extraídos de um subsistema de distribuição de energia da *New Zealand Electrical* composto por nove subestações. No estudo de Ferreira, resultados MAPEs obtidos para as nove subestações ficaram abaixo de 3,5%. Já no estudo feito por Junior os erros MAPEs ficaram entre 3,5% a 12,3%. Comparando as metodologias, a proposta por Ferreira é mais promissora.

Não obstante, as RNAs possuem algumas limitações. É difícil determinar a topologia da rede, a qual a sua escolha acontece de forma empírica (PIMENTA, 2019). Com isso é difícil determinar o número de camadas e neurônios da estrutura da rede

(LI, 2021). Estas limitações influenciam na avaliação do erro e no tempo de convergência da rede.

Diante deste fato, métodos híbridos foram desenvolvidos ao longo dos anos (LI, 2021). A ideia é combinar dois ou mais métodos a fim de um método suprir a limitação do outro. A escolha da combinação de métodos depende das características do problema e da precisão que se deseja alcançar.

Em comparação com um modelo de previsão de método único, os modelos híbridos têm precisão e estabilidade superiores (LUO; ZHANG; WANG, 2022). Embora os modelos de método único tenham resultados plausíveis, inevitavelmente apresenta algumas limitações, gerando falhas na previsão ou dificuldade de adaptar dados complexos. Para melhorar a capacidade de extrapolação e reduzir o tempo de aprendizado das RNAs, foram combinadas com alguns métodos.

Zhang *et al.* (2018) propôs um modelo híbrido baseado em decomposição de modo empírico aprimorado ARIMA e rede neural *wavelet* otimizada pelo algoritmo de otimização de mosca da fruta.

Zou *et al.* (2018) combina as redes com o ARIMA para previsão de carga. Primeiro extrai amostra de dados de séries temporais em termos da tendência de variação da carga elétrica, depois aplica redes neurais para fazer a correção dos erros de previsão e, por fim, adiciona o valor corrigido com o valor previsto ARIMA. Os resultados mostram que o erro relativo médio obtido foi de 0,042. O estudo foi comparado para a previsão feitas com as redes neurais e ARIMA separadamente e verificou que a combinação dos dois métodos foi mais satisfatória comprovando que é viável combinar vários métodos.

Diversos estudos vêm sendo publicados com a finalidade de fazer previsões de carga cada vez mais precisas. A *Matworks* publicou em sua plataforma o estudo de Deoras (2012) na qual demonstra a construção de um sistema de previsão de carga a curto prazo da região *NEPOOL* (ISO New Inglaterra). Foi abordado também como converter o modelo de previsão de carga em um modelo de previsão de preço. Dois modelos de regressão não linear (Redes Neurais e Árvores de Regressão *Bagged*) foram calibrados para prever as cargas horárias do dia seguinte, dadas os valores da temperatura, informações de feriados e cargas históricas. Os modelos foram treinados nos dados dos anos de 2004 a 2007 e testados nos dados do ano de 2008. Os modelos propostos foram capazes produzir previsões para o dia seguinte

com erros médios em torno de 1 a 2%. Além disso, a demonstração incluiu relatórios publicáveis, bem como um *front-end* do Excel que permite aos usuários chamar a previsão de carga treinada por meio de uma *Dynamic-link library* (DLL) implantada pelo *Matlab*.

A justificativa do lançamento deste estudo é que, segundo o autor, previsões de carga são críticas para operações de curto prazo e planejamento de longo prazo para concessionárias, influenciando em uma série de decisões, incluindo quais geradores serão comprometidos por um determinado período, e ainda como isso afeta os preços do mercado atacadista de eletricidade. Outro ponto citado pelo autor é que tradicionalmente, as concessionárias usam pacotes de *software* comercial para realizar previsões de carga. A principal desvantagem destes é que eles são como uma “caixa preta”, não oferecendo transparência sobre como a previsão de carga é calculada.

O mesmo estudo foi publicado por outros autores na plataforma da *Matworks*. Pode se citar Hernández (2013) e Willingham (2012). Willingham além de fazer o mesmo estudo, ele replicou o estudo a realidade da Austrália. Mesmo com dados históricos diferentes, ele conseguiu produzir erros médios dentro da faixa de 2%.

Este estudo serviu de base a outros. Aydarous, Elshahed e Moustafa Hassan (2018), utilizando os mesmos dados, mas com métodos diferentes, comparou-se os erros percentuais médios do seu modelo de previsão de carga com os erros do estudo de Deoras (2012). O método proposto por Aydarous, Elshahed e Moustafa Hassan (2018) consiste em uma abordagem na qual reconhece os diversos fatores relevantes que afetam a carga no curto prazo. O estudo utiliza quatro tipos de observadores: horas, dias, semanas, e anos anteriores analisando a correlação para cada um deles. Com esta análise, foi implementada, via Rede Neural Artificial (RNA), pelo *software Matlab*, um modelo de previsão que tem quatro métodos de entrada diferentes, todos utilizando uma variável. Os autores perceberam que esta abordagem reduziu o erro percentual médio consideravelmente.

Utilizando a mesma rede neural e os dados testes, Singh, Hussain e Bazaz (2017) propuseram uma abordagem diferente. Como o perfil de carga é diferente para dias de semana e finais de semana, para melhor desempenho de previsão, o

treinamento da rede neural foi feito separadamente. O desempenho do previsor foi calculado usando *Mean absolute error* (MAE), *Mean Absolute Percentage Error* (MAPE) e o erro de previsão de pico diário. Obteve-se um MAPE de 1,38% para dias de semana e 1,39% para fins de semana, o que mostra que a separação dos dados não prejudicou o resultado da previsão.

Este presente TCC pretende aplicar estes estudos para prever a carga a curto prazo no submercado sul do SIN, buscando os menores erros percentuais possíveis.

3 SÉRIES TEMPORAIS

A análise de dados de séries temporais é uma forma de estudar as características da variável de resposta em relação ao tempo como variável independente (PANDIAN, 2023). Uma série temporal representa uma série de ordens baseadas no tempo que pode ser discretizados em anos, meses, semanas, dias, horas, minutos e segundos. Consiste na análise de uma série de eventos que ocorrem em momentos distintos e separados no tempo.

As séries temporais podem ser classificadas em: estacionária e não estacionária (GUTIERREZ, 2003; PANDIAN, 2023). Uma série temporal é estacionária quando as características estatísticas, como média e a variância são constantes e a covariância é independente do tempo. Se as características estatísticas estão mudando em relação ao tempo, o conjunto de dados é chamado de não estacionário.

A maior parte das series temporais apresentam algum aspecto de não estacionariedade (MORETTIN; TOLOI, 1987). Alguns padrões de comportamento, comumente, encontrados em séries temporais não estacionaria (BARROS *et al.*, 2017; MORETTIN; TOLOI, 1987) são: tendência, sazonalidade e ciclos.


A tendência é um elemento característico da estrutura organizada de uma série temporal, que permite determinar se os valores da série estão mostrando um padrão de crescimento ou decrescimento ao longo do tempo. Identificar a tendência é crucial para analisar a direção da série e a rapidez com que os dados estão se desenvolvendo, seja um crescimento rápido (exponencial) ou moderado (polinomial) (SOUSA *et al.*, 2021).

Sazonalidades são variações nos valores de uma variável que ocorrem em períodos inferiores a um ano e se repetem anualmente, normalmente estão relacionadas às estações do ano (SOUZA, 2020).

Ciclos são oscilações ascendentes ou descendentes que ocorrem repetidamente ao longo do tempo, dentro de um padrão geral de tendência, sem período fixo e dentro de um período maior que um ano (BARROS *et al.*, 2017). “A diferença essencial entre as componentes sazonal e cíclica é que a primeira possui

movimentos facilmente previsíveis, ocorrendo em intervalos regulares de tempo, enquanto que movimentos cíclicos tendem a ser irregulares e de comprimento maior”(SANTANA; SILVA; SANTOS, 2011). A Figura 1 ilustra esta diferença.

Figura 1 - Diferença entre sazonalidade e ciclo.



Fonte: Santana, Silva e Santos (2011).

Destaca-se que tendência, sazonalidade e ciclos não são necessariamente observados de maneira independente. É comum encontrar combinações dessas componentes em uma mesma série de dados (BARROS *et al.*, 2017).

Além destes comportamentos, as séries temporais podem apresentar irregularidade. A irregularidade em uma série temporal é vista como um ruído ou um erro aleatório presente no modelo. Tudo aquilo que não representa uma tendência, um ciclo ou uma sazonalidade é considerado uma irregularidade. Quando a componente irregular é significativa, pode se tornar difícil isolar outros componentes individuais do modelo. Alguns dados são puramente de erros aleatórios. Em tais casos, recorre-se a técnicas para realizar previsões de curto prazo (SOUSA *et al.*, 2021).

A correlação entre as séries temporais é um outro aspecto relevante a ser analisado. Ela nos ajuda a identificar a influência que uma variável exerce sobre as outras, ou seja, se elas tendem a aumentar ou diminuir em conjunto.

Ao lidar com séries temporais, é importante identificar tais características. Uma forma de identificar é desenvolver gráficos para entender a sua natureza. Também é crucial garantir a consistência dos dados, verificando se não há lacunas ou valores ausentes. Para modelos de previsão baseados em IC, eles não são tão afetados por valores ausentes comparado com os métodos estatísticos, portanto, o processo de limpeza pode ser limitado (PANDIAN, 2023).

Uma das limitações ao lidar com séries temporais é que elas podem ser afetadas pela generalização. Erros humanos na escolha do modelo de dados adequado podem ter um efeito cumulativo nos resultados, levando a consequências indesejáveis. É fundamental escolher cuidadosamente as técnicas de modelagem e previsão, levando em conta a natureza dinâmica das séries temporais.

4 INTELIGÊNCIA COMPUTACIONAL

A invenção dos computadores proporcionou uma facilidade para construir e estudar sistemas que exibem características ou comportamento tradicionalmente atribuídos à inteligência, mas não são naturais no sentido da inteligência humana (CRAENEN; ELBEN, 2002). A ciência emergente por trás era comumente chamada de inteligência artificial (IA) que abrangia qualquer abordagem de sistemas inteligentes. Contudo, seu significado era restrito pelas convenções da comunidade de pesquisa de IA.

A IA tradicional é direcionada para representações e raciocínio de forma *top-down*. Ou seja, a estrutura de um determinado problema (ambiente, contexto de domínio) é analisada previamente e o sistema inteligente é construído com base nisso (CRAENEN; ELBEN, 2002).

Ainda segundo Craenen e Elben (2002), com o passar do tempo, foi argumentado que existe um grupo de abordagens alternativas para realizar características ou comportamentos inteligentes. Essas abordagens, mesmo que diferentes entre si, operam de baixo para cima (*bottom-up*), onde a estrutura emerge de um início desordenado, ao invés de ser imposta de cima. Estas abordagens foram agrupadas sob o nome de inteligência computacional (IC).

A área de investigação da IC compreende conceitos, paradigmas, algoritmos e implementações para desenvolver sistemas que exibam comportamento inteligente em ambientes complexos (KRUSE *et al.*, 2013). A IC é composta por três campos: Redes Neurais, Logica Fuzzy e Computação Evolutiva (LEE *et al.*, 2021). Sua estratégia é aplicar técnicas e métodos de aproximação que buscam soluções válidas para determinados problemas.

Neste capítulo será apresentado uma breve explicação sobre as redes neurais artificiais.

4.1 Redes neurais artificiais

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano (MULUALEM; LIOU, 2020; RUNGE; ZMEUREANU, 2019), capazes de aprender a partir de dados.

Essas redes são compostas por múltiplas camadas de neurônios artificiais, que processam informações e transmitem sinais para as camadas subsequentes. RNAs têm sido largamente usadas nas áreas de reconhecimento de imagens, processamento de linguagem natural, previsão de séries temporais e outras tarefas de aprendizado de máquina.


Uma das vantagens em se utilizar uma RNA é que ela é capaz de aprender por intermédio de exemplos e fazer inferências sobre o que aprendeu, melhorando o seu desempenho gradativamente (FERNEDA, 2006; MAHANTA, 2017). Além disso as RNAs não impõem restrição alguma nas variáveis de entrada nem como elas devem ser distribuídas e podem modelar melhor os dados com alta volatilidade e variância não constante (MAHANTA, 2017).

Uma das dificuldades encontradas em se utilizar as RNAs é a escolha da melhor arquitetura, sendo que esse processo é experimental e pode demandar esforço e experiência (FLECK *et al.*, 2016).

4.1.1 Neurônio Artificial

O cérebro humano é composto de bilhões de células chamadas neurônios que processam informações na forma de sinais elétricos (MAHANTA, 2017). Um neurônio é uma célula formada por três seções com funções específicas e complementares: corpo, dendritos e axônio (FERREIRA, 2020). Estímulos externos são captados pelos dendritos do neurônio, processados no corpo celular do neurônio, convertidos em uma saída e passados através do axônio para o próximo neurônio. O próximo neurônio pode aceitar ou rejeitar esta informação, a decisão depende da intensidade do sinal. A Figura 2 ilustra as partes de um neurônio biológico.


Figura 2 - Representação de um neurônio biológico.



Fonte: Adaptado Kruse et al. (2013).

Uma RNA é um sistema de processamento de informações inspirado por neurônios interconectados do sistema biológico (RUNGE; ZMEUREANU, 2019). Pimenta (2019) complementa que, “As RNAs são sistemas paralelos distribuídos compostos por unidade de processamento, chamados de neurônios artificiais, que calculam determinadas funções matemáticas, lineares e não lineares”. A Figura 3 apresenta um neurônio artificial.

Figura 3 - Neurônio artificial




Fonte: Adaptado Haykin (2009).

Segundo Haynk (2001, p. 36-37), existe três elementos básicos do modelo neuronal:

- a) O conjunto de entrada ($X_1, X_2, \dots, X_n$), são sinais externos conectados ao neurônio k e multiplicado por pesos sinápticos ($W_1, W_2, \dots, W_n$). Estes pesos ponderam cada uma das variáveis de entrada. O peso sináptico de um neurônio artificial pode estar em um intervalo que incluem valores positivos e negativos.
- b) O somador (Σ) também conhecido como combinador linear, somam os sinais de entrada, ponderados pelos seus respectivos sinapses do neurônio.
- c) A função de ativação restringe a amplitude da saída de um neurônio, limitando o intervalo permissível a um valor finito. A amplitude da saída de um neurônio é escrita como um intervalo unitário fechado $[0, 1]$ ou alternativamente $[-1, 1]$.

As principais funções de ativação são: linear (identidade), *sigmoide*, *relu* e tangente hiperbólica. Figura 4 apresenta estas funções.

Figura 4 - Principais funções de ativação para as RNA.



Fonte: Adaptado de (RIZZO; CANATO, 2020; SANTOS, 2021).

O modelo neuronal inclui também um bias aplicado externamente que tem o efeito de aumentar (valores positivos) ou diminuir (valores negativos) a entrada líquida da função de ativação (HAYKIN, 2001, p. 36–37).

4.1.2 Arquitetura de uma Rede Neural

As RNAs se distinguem pela sua arquitetura e pela forma como os pesos são associados às conexões durante o processo de aprendizado (FERNEDA, 2006). Em uma arquitetura de uma rede, o neurônio, recebe a entrada que consiste em dados brutos. Estes dados são processados e entregados à saída, que pode ser um resultado ou ser utilizado como entrada para outros elementos de processamento (AZIZ; LECTURER, 2020). Comumente, uma RNA consiste em grupos de neurônios agrupados em diferentes camadas. Estas camadas são divididas em: a camada de entrada, a camada oculta e a camada de saída (MILKE, 2019). A camada oculta é responsável por transformar os dados da camada de entrada em dados adequados para a camada de saída. Além do número de camadas, a arquitetura de uma rede também é caracterizada pelo número de nós em cada camada, tipo de conexão entre nós e por sua topologia (HAYKIN, 2001).

As redes neurais mais profundas possuem uma maior capacidade para aprender em situações complexas, no entanto, isso pode resultar em um aumento no tempo de processamento (SANTOS, 2021). É aconselhável iniciar com uma ou duas camadas, pois elas são eficazes na maioria dos problemas (GÉRON, 2019). No entanto, se necessário, é possível aumentar gradualmente o número de camadas.


Em geral, as principais arquiteturas de rede são: rede *feedfoward* (alimentadas adiante) de camada simples, redes *feedfoward* de múltiplas camadas e redes recorrentes (FLECK *et al.*, 2016; HAYKIN, 2001; MILKE, 2019).

4.1.2.1 *Feedfoward de camada simples e múltiplas camadas*

Em uma rede neural os neurônios são organizados em camadas. Na sua forma mais simples, uma rede em camadas, tem-se uma camada de entrada conectada diretamente à uma camada de saída de neurônios, mas não vice-versa (FREITAS; BRAGA, 2020; HAYKIN, 2009). Este tipo de configuração é chamado de

feedforward de camada simples, também conhecida como *perceptron* simples. A Figura 5 ilustra uma estrutura de rede *feedforward* de camada simples contendo quatro nós nas camadas de entrada e saída.

Figura 5 - Representação de uma Rede *Feedforward* de Camada simples.




Fonte: Adaptado Haykin (2009).

Quando neste tipo de estrutura há a presença de camadas ocultas a rede passa a ser denominada de Rede *Feedforward* de Múltiplas Camadas ou *Perceptron* de Múltiplas Camadas (MLP). Essas camadas ficam entre a camada de entrada e de saída. A função dos neurônios ocultos é intervir entre a entrada e a saída, tornando a rede capaz de extrair, estatísticas de ordem elevada (HAYKIN, 2001).

Os nós da camada de entrada da rede fornecem sinais a segunda camada. Os sinais de saídas da segunda camada são utilizados como entradas para a terceira camada, e assim por diante até o final da rede. A Figura 6 exemplifica uma rede *feedforward* de camadas múltiplas 10-4-2 (10 neurônios de entrada, 4 neurônios ocultos e 2 neurônios de saída).

Figura 6 - Representação de uma Rede *Feedforward* de Camada Múltiplas.



Fonte: Adaptado Haykin (2009).


4.1.2.2 Redes neurais recorrentes

As redes neurais recorrentes (RNN) processam dados sequenciais. Elas se distinguem de uma rede neural *feedforward* por ter pelo menos um laço de realimentação (*loop de feedback*) onde o resultado do passo anterior é realimentado na rede, de modo que afete o passo seguinte sucessivamente (MATSUMOTO, 2019). Desta maneira, a informação não flui em um único sentido, a saída da rede não depende mais apenas do neurônio que está conectada, mas também de outros neurônios (NELSON, 2017).

Uma RNN, pode ter por exemplo, uma única camada de neurônios, com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios. Ou pode conter auto realimentação na qual a saída de um neurônio é realimentada para a sua própria entrada. Além disso, as redes recorrentes podem

conter neurônios ocultos onde as conexões de realimentação se originam destes neurônios. A Figura 7 ilustra duas possíveis estruturas de conexão de uma rede recorrente. A primeira estrutura é uma rede recorrente sem laços de auto realimentação e sem neurônios ocultos. Já a segunda estrutura é uma Rede recorrente com neurônios ocultos e sem laços de auto realimentação.

Figura 7 - Exemplos de conexões de uma rede recorrente.



Fonte: Adaptado Haykin (2009).

“As redes recorrentes geram modelos dinâmicos capazes de captar as relações sequenciais dos exemplos anteriores e integrar essas informações no processo corrente”(MATSUMOTO, 2019). Por ter esta capacidade de integração a rede neural adquire a capacidade de memória de curto prazo. Por essa característica, são muito usadas no estudo de previsão de séries temporais.

Mesmo sendo capazes de reutilizar informações para o processo corrente, as RNN sofrem com problemas na magnitude dos gradientes conhecido como gradiente de fuga, que significa que a rede só pode lembrar de entradas recentes e rapidamente esquece entradas de longo prazo. Como uma solução para este problema, foi incluída uma variante do RNN conhecida como *Long Short Term Memory* (Memória de longo prazo), LSTMs (LEANDRO, 2021; MATSUMOTO, 2019).

As LSTMs, criadas por Hochreiter e Schmidhuber (1997), são variações especiais de redes recorrentes, capazes de aprender dependências de longo prazo e relembrar informações por períodos mais longos. A principal diferença das LSTMs


com as redes recorrentes é a presença de portões *gates*. Os portões são uma forma opcional que permite a passagem de informações (ANDRADE FILHO, 2021). Através destes portões é possível manter o fluxo do erro constante e permitem ajustes de pesos da mesma forma que o truncamento da sequência quando a informação não é mais necessária (NELSON, 2017).

A LSTM possui uma estrutura em cadeia que contém quatro camadas de redes neurais e diferentes blocos de memória chamados células interagindo entre si (ANDRADE FILHO, 2021). Na arquitetura de uma LSTMs, cada neurônio mantém um estado e possui três *gates*: *input gate*, *output gate* e *forget gate*. Sendo que cada uma afeta o estado da célula de maneira diferente.

- a) *Input Gate*: responsável por fazer a adição de informações úteis ao estado da célula;
- b) *Output Gate*: responsável por extrair informações úteis do estado da célula atual para ser apresentadas como uma saída;
- c) *Forget Gate*: responsável por remover as informações que não são mais úteis no estado da célula.

A Figura 8 ilustra estes *gates*.

Figura 8 - Arquitetura de uma LSTM.



Fonte: Deep Learning Book (2022).

Estes portões são compostos por uma função de ativação *sigmoide* de níveis 0 e 1. Sendo que, 0 está completamente fechado, ou seja, não deixa passar nada e 1 está completamente aberto, pode passar tudo (ANDRADE FILHO, 2021).

As LSTMs apresentam algumas desvantagens. Comparado com as RNNs tradicionais requerem mais dados de treinamento para aprendizado de forma eficaz. Exigem mais recursos e tempo para o treinamento. Isso se deve ao fato de que eles devem aprender os parâmetros das células LSTM, o que pode ser computacionalmente intensivo. Finalmente, LSTMs podem não ser apropriados para todos os tipos de dados. Por exemplo, não funcionam bem com dados altamente não lineares ou com muito ruído (SUGANDHI, 2023).

As LSTM é o modelo de escolha deste trabalho, visto que, são capazes de modelar quase perfeitamente problemas com múltiplas variáveis de entrada. Este é um grande benefício na previsão de séries temporais, onde os métodos lineares clássicos podem ser difíceis de adaptar a problemas de previsão multivariados ou de entrada múltipla (BROWNLIE, 2017).

4.1.3 Processo de Aprendizagem de uma Rede Neural Artificial

As redes neurais “aprendem” através de experiências vividas, como um ser humano na infância que aprende a falar, andar e associar objetos e nomes. A partir das experiências vividas, junto à um conjunto de treinamento, as RNAs adquirem um conhecimento, capazes de gerarem uma solução aproximada para um determinado problema. Essa conexão é estabelecida a partir de dados históricos.

A capacidade de uma RNA de estimar uma solução desejada com certa margem de erro é alcançada por meio do treinamento da rede com o uso de um algoritmo de aprendizagem. Esse algoritmo é responsável por ajustar os parâmetros da RNA de forma a obter a solução desejada em um número limitado de iterações (DISCONZI, 2018).

No processo de aprendizagem a RNA extrai informações relevantes de padrões de informação apresentados a ela, dando origem a uma representação própria do problema (FLECK *et al.*, 2016). Este processo depende da maneira pela

qual os neurônios estão estruturados. O processo iterativo de ajustes aplicados aos pesos sinápticos da RNA, é chamado treinamento.

Neste processo, o conjunto de dados disponível é dividido em dois subconjuntos: dados de treinamento e dados de teste. O subconjunto de treinamento é utilizado para a construção do modelo, ao passo que o de teste é usado para avaliar a habilidade preditiva do modelo (CUNHA JÚNIOR; FIRMINO, 2022). Nesse procedimento, os valores dos pesos sinápticos que conectam as diferentes partes da rede são modificados conforme os dados de entrada são inseridos, com o intuito de alcançar a meta desejada ou o melhor resultado possível.

As RNAs podem ser diferenciadas quanto à forma de aprendizagem: aprendizado supervisionado e aprendizado não supervisionado (BUI; NGUYEN; NGO, 2009; CUNHA JÚNIOR; FIRMINO, 2022; DISCONZI, 2018; FERNEDA, 2006; PINTAR, 2018; SILVA, 2003). Sendo que a principal diferença é a presença ou não de um supervisor externo (professor).

No aprendizado supervisionado, os valores de entrada e seus correspondentes padrões de saídas são apresentados a rede por um supervisor externo. Por conseguinte, é importante possuir um conhecimento antecipado do comportamento almejado ou esperado da rede. Em cada entrada, um "professor" indica explicitamente se a resposta produzida é considerada adequada ou insuficiente. A saída obtida pela rede neural é comparada à saída esperada e a diferença entre ambas é comunicada à rede, para que ela possa ser aprimorada em suas futuras respostas (FERNEDA, 2006) .

No aprendizado não supervisionada os valores de saída são desconhecidos e somente valores de entrada são apresentados a rede (BUI; NGUYEN; NGO, 2009). A rede processa as entradas e, detectando suas regularidades, tenta estabelecer representações internas progressivamente para codificar características e classificá-las automaticamente (FERNEDA, 2006). Este tipo de aprendizado só é possível quando existe redundância nos dados de entrada, para que se consiga encontrar padrões.

Segundo Pinta (2018) é possível combinar estes dois métodos de aprendizado: Aprendizado híbrido. Parte dos pesos são determinados pelo

aprendizado supervisionado e a outra parte através do aprendizado não-supervisionado.

Para as redes neurais recorrentes o aprendizado não pode ser classificado em supervisionado e não supervisionado. O aprendizado envolve a alimentação do modelo com um conjunto de dados de treinamento, que consiste em entradas e saídas desejadas. A rede neural, inicialmente com parâmetros aleatórios, faz previsões com base nessas entradas e os resultados são comparados com as saídas desejadas.

A diferença entre as previsões da rede neural e as saídas desejadas é medida através de uma *loss function* (função de perda). “A função de perda é a função que calcula a distância entre a saída atual do algoritmo e a saída esperada”(PERE, 2020).

O objetivo é minimizar essa função de perda, ajustando os pesos e parâmetros da rede neural por meio de um processo chamado de *backpropagation through time* (retropropagação através do tempo) (GÉRON, 2019).

O processo de *backpropagation through time* é dividido em duas fases: *forward* e *backward*. Na fase *forward*, em um intervalo de tempo específico, as informações são processadas em uma rede neural. O vetor de entrada e o vetor de estado oculto do intervalo de tempo anterior são multiplicados por matrizes de peso específicas e somados em um nó de adição. Em seguida, passam por uma função não linear e são duplicados: um deles é usado como entrada para a próxima etapa de tempo, enquanto o outro é enviado para uma camada de classificação. Nessa camada, o vetor é multiplicado por outra matriz de peso para obter o vetor de *logits*, que é usado para calcular a perda (KRISHNA, 2022).

Na fase *backward*, começa-se de trás para frente calculando o gradiente da perda de classificação em relação ao vetor de *logits*. Esse gradiente flui de volta para o nó de multiplicação de matriz, onde calcula-se os gradientes em relação à matriz de pesos e ao estado oculto. O gradiente em relação ao estado oculto flui de volta para o nó de duplicação, onde se encontra com o gradiente do passo anterior. Uma RNN processa sequências, um passo de cada vez, portanto, durante a retropropagação, os gradientes fluem de volta através dos passos de tempo. Assim, o gradiente em relação ao estado oculto e o gradiente do passo anterior se encontram no nó de duplicação, onde são somados (KRISHNA, 2022).

Uma vez treinada, a rede neural pode ser usada para fazer previsões em novos dados de entrada, onde ela tenta generalizar o conhecimento adquirido durante o treinamento para realizar previsões precisas.

5 PREVISÃO DE CARGA PARA A PROGRAMAÇÃO DIÁRIA ELETROENERGÉTICA DO SEB PELO ONS

O sistema elétrico brasileiro (SEB) é caracterizado por um sistema interligado nacional (SIN). O SIN é responsável pela geração, transmissão e distribuição de energia elétrica em todo o território. A integração destes recursos permite o atendimento ao mercado com segurança e economicidade (ONS, 2021c).

O SIN é constituído por quatro subsistemas: Sul, Sudeste/Centro-Oeste, Nordeste e a maior parte da região Norte, sendo que o seu sistema de geração é um sistema hidro-termo-eólico de grande porte, com predominância de usinas hidrelétricas. Também há uma participação de outras fontes de energia, como a solar e a nuclear. E é por meio de uma extensa malha de transmissão que é feita a interconexão dos subsistemas permitindo a transferência de energia e a obtenção de ganhos sinérgicos explorando a diversidade entre os regimes hidrológicos das bacias (ONS, 2021a).

Atualmente, o ONS apresenta em tempo real, em sua página da internet, o balanço de energia. O balanço de energia apresenta uma à comparação entre a oferta e a demanda, sendo possível verificar o desempenho do SIN de acordo com estas informações.

Ademais, no balanço de energia, é comum observar a participação das diferentes fontes de geração, como hidrelétrica, termelétrica, eólica, solar, entre outras. Também é possível acompanhar as variações sazonais na oferta de energia, principalmente em relação à geração hidrelétrica, que é influenciada pelo regime de chuvas.

Acompanhar o balanço de energia tem como finalidade principal atender a demanda dos consumidores que estão conectados à rede. O planejamento e otimização da operação é essencial para que haja um fornecimento contínuo de energia, com custos mínimos, ao mesmo tempo em que são observados critérios de segurança estabelecidos (BONVICINE, 2021)

A previsão de carga é vital na programação diária da operação. Estimar de forma precisa a demanda de energia ao longo do dia garante um despacho ótimo de

usinas além de atender toda a rede consumidora. Diante disso, o ONS tem em sua rotina a Programação Diária da Operação Eletroenergética (PDE). Esta rotina é responsável por fazer as previsões de carga para às áreas de concessão dos agentes distribuidores e consumidores livres conectados à rede de distribuição.

Segundo ONS (2019), as previsões vêm sendo elaboradas no dia anterior ao dia da operação, com intervalos de meia hora, para um horizonte que varia de 2 a 7 dias à frente. Normalmente, estas previsões são para dias úteis ou finais de semana precedidos e/ou seguidos de feriados e dias pontes. Previsões para dias especiais, como jogos do Brasil em copas do mundo, são elaboradas com maior antecipação porque consideram comportamentos de consumo de energia elétrica fora dos padrões normalmente observados, exigindo medidas operativas especiais.

A variação do comportamento da carga diária é influenciada por diferentes fatores, pode-se citar, as mudanças nas temperaturas e/ou condições climáticas de cada região. Além disso, eventos como feriados, dias pontes, transições para o horário de verão e dias especiais também contribuem para a incerteza do comportamento da carga. Também, fatores econômicos e sazonais desempenham um papel importante, pois podem modificar o perfil da curva diária de consumo de energia.

Para lidar com essas incertezas, é crucial contar com previsões meteorológicas precisas para o período desejado. Além disso, os modelos utilizados para estimar o comportamento da carga devem levar em consideração os principais fatores que a afeta. Ademais, é necessário ter acesso a uma ampla base de dados que inclua curvas de carga diária observadas, juntamente com dados meteorológicos correspondentes e outros indicadores relevantes. O ONS dispõe de uma base de dados de cargas relativas aos subsistemas do SIN, além de temperaturas observadas e previstas em diversas localidades.

O processo responsável pelas previsões de carga para a PDE no ONS é chamado de Consolidação da Previsão da Carga Diária e se subdivide em:

- a) leitura das séries temporais de cargas verificadas por áreas e subsistemas em intervalos de meia hora e/ou em intervalos em dia corrente até o momento da previsão;
- b) leitura das séries temporais de temperaturas verificadas e previstas em intervalos horários para o dia da operação. As temperaturas

consideradas são provenientes dos modelos de previsão do CPTEC (Centro de Previsão de Tempo e Estudos Climáticos) para as capitais do país;

- c) geração de cenários de carga através de modelos de previsão de carga de curto prazo considerando principalmente cenários meteorológicos;
- d) análise e tomada de decisão;
- e) envio das previsões para o processo da PDE.

A etapa mais crítica é a tomada de decisão, pois envolve a criação de uma curva de carga diária específica para cada área e subsistema no dia de operação. O objetivo principal desse processo é minimizar as discrepâncias entre as previsões de carga e a carga real nas áreas e subsistemas monitorados pelo operador, a fim de garantir a segurança do sistema elétrico e manter tarifas acessíveis (ONS, 2019).


5.1 Processo da previsão da carga diária

O processo da Consolidação da Previsão da Carga Diária se subdivide em quatro etapas (ONS, 2019) e pode ser observada na Figura 9:

- a) leitura e gravação das séries temporais de cargas e temperaturas, cujos dados são provenientes, respectivamente, dos sistemas da operação REGER (Rede de Gerenciamento de Energia), SAGIC (Sistema de Apuração da Geração, Intercâmbio e Carga) e de arquivos formato texto;
- b) tratamento de *missings* e *outliers* baseados em modelos estatísticos, cujos modelos foram desenvolvidos, pela Universidade federal do Rio de Janeiro (UFRJ), Centro de Pesquisas de Energia Elétrica (CEPEL) e ONS;
- c) geração de cenários de cargas através de modelos de previsão de curto prazo desenvolvidos pelo CEPEL e ONS, além do *Artificial Neural Network Short-Term Load Forecaster* (ANNSTLF) desenvolvido pelo *Electric Power Research Institute* (EPRI).

d) análise, tomada de decisão e envio das previsões consolidadas para a PDE.

Figura 9 - Visão Geral do Processo da Consolidação da Carga Diária.



Fonte: ONS (2019).

As projeções produzidas pelos modelos são utilizadas como base para a tomada de decisão, assim como as projeções finais para as diferentes áreas e subsistemas enviados ao processo da PDE, são registradas na base de dados do Sistema de Previsão de Carga para os Estudos Elétricos e Energéticos (SPCEE). Essa medida visa possibilitar a análise de discrepâncias, o aperfeiçoamento dos modelos e a auditoria (ONS, 2019).

5.1.1 Leitura e gravação dos dados de cargas e temperaturas

Todas as informações relacionadas à previsão de carga diária são armazenadas em um banco de dados do tipo relacional, sendo gerenciado pelo departamento de tecnologia da informação do ONS. Além desse banco de dados o sistema SPCEE permite o gerenciamento dos dados armazenados, incluindo adição, edição, exclusão e consulta e realiza processos de entrada e saída de dados. As séries temporais do banco de dados são atualizadas diariamente durante a

madrugada e a cada 10 minutos ao longo do dia, podendo também serem atualizadas mediante comando do usuário. Além das séries de carga e temperatura, o sistema também inclui tabelas relacionadas a feriados, dias especiais, horário de verão, associação de séries temporais a dias especiais, entre outros.

5.1.2 Tratamento de *missings* e *outliers*

Durante o processo de armazenamento de dados, o sistema automaticamente aplica um modelo de tratamento de dados faltantes (*missings*) e valores discrepantes (*outliers*) desenvolvido pela UFRJ. Esse modelo utiliza um filtro baseado na Teoria da Informação, dividido em duas etapas. A primeira dela identifica valores discrepantes nas séries de carga e temperatura. A segunda substitui os valores discrepantes por estimativas de acordo com as regras de inferência do modelo. A inferência é baseada em um conjunto de suporte, que consiste em curvas de carga semelhantes ao dia em questão. Esse conjunto de suporte é fornecido como parâmetro de entrada para o modelo. O tamanho desse conjunto de dados varia de acordo com o tipo de dia (útil, final de semana, feriado, etc.), o que requer um histórico de dados adequado. Para atender a esse requisito, o sistema foi projetado para armazenar, no mínimo, os últimos 20 anos de dados de carga observados em feriados e dias especiais, e no mínimo os últimos 5 anos de dados de carga e temperatura em relação ao dia atual.

5.1.3 Modelos de previsão

Como dito anteriormente, o ONS utiliza os modelos ANNSTLF, CEPEL e ONS para realizar as previsões de carga à curto prazo.

O ANNSTLF é um modelo baseado em redes neurais do tipo *feedforward*. É composto de duas redes neurais: B(R)LF (*Base or Regular Load Forecaster*) e C(D)LF (*Change or Delta Load Forecaster*) além do módulo RLS (*Recursive Least Squares*), responsável pela combinação linear das saídas das redes C(D)LF e B(R)LF e pelo resultado final do modelo.

Esse modelo foi licenciado para uso exclusivo do ONS e está incorporado em um software fechado, projetado para ser utilizado por um único usuário. O usuário

precisa alimentar manualmente o software com as curvas de carga diárias verificadas no dia anterior, em intervalos de hora em hora, bem como as temperaturas verificadas no dia anterior também em intervalos de hora em hora. O modelo gera como resultado curvas de carga previstas em intervalos horários, correspondentes ao mesmo horizonte das temperaturas previstas inseridas para a série temporal em questão.

Além das previsões de cargas o software oferece: cadastramento dos feriados e dias especiais, o treinamento das redes neurais, a combinação de previsões para feriados e semiferiados (combinação de dias comuns com sábados ou domingos e de sábados com domingos), relatórios com as análises de desempenho do modelo, parâmetros de configuração, entre outros.

Já o modelo do CEPEL é baseado em *Support Vector Regression* (SVR) e foi desenvolvido em linguagem R (R é uma linguagem de programação e um ambiente de software livre para computação estatística e gráficos e é apoiado pela *R Foundation for Statistical Computing* (R FOUNDATION, 2023). O software é dividido em de três partes (ONS, 2019): interface ao usuário, preparação e leitura das series temporais e o modelo de previsão.

A interface, desenvolvida pelo ONS, permite a configuração, execução, exibição e exportação dos resultados do modelo, em R *Shiny*. Com o software é possível fazer a leitura das series temporais e outros dados nas bases do ONS e os prepara-los como “*decks*” de entrada para o modelo. Estes “*decks*” são arquivos no formato *dataframe*, i.e., um tipo de dados do R.

A interface é operada pelo usuário a partir de um navegador da *web* e todo o processo ocorre automaticamente, sem a necessidade de digitar dados, ao contrário do software ANNSTLF. Os gráficos e tabelas com as previsões de carga são exibidos em abas separadas no navegador. Os resultados das tabelas podem ser exportados para planilhas ou arquivos de texto, facilitando o uso na tomada de decisões.

Por fim, o modelo desenvolvido pelo ONS consiste em um conjunto de diferentes modelos: Regressão Dinâmica, Redes Neurais, SVR, Regressão Quantílica e Similaridade de Temperaturas (ONS, 2019). Esses modelos foram implementados na linguagem R e a interface do usuário foi criada utilizando o R *Shiny*. A execução do modelo também ocorre através de um navegador, onde o usuário pode configurar as opções de previsão.

Nessa aplicação, o usuário tem a opção de realizar previsões usando um único modelo ou combinar vários deles. Além disso, a interface exibe os valores mínimos, médios e máximos previstos por todos os modelos selecionados em cada intervalo. Os resultados são apresentados no próprio navegador por meio de gráficos e tabelas, sendo possível também exportá-los para planilhas ou arquivos de texto.

A interface também oferece a funcionalidade de exportar as previsões de todos os modelos selecionados, incluindo os valores mínimo, médio e máximo, em arquivos de texto. Esses arquivos podem ser importados automaticamente pela planilha utilizada no processo de tomada de decisão.

5.1.4 Tomada de decisão

A tomada de decisão é efetuada para cada área e subsistema através de uma planilha *Microsoft Excel*. Que tem por objetivo dar flexibilidade ao analista para elaborar curvas de cargas previstas para as áreas e subsistemas, permitindo ajustes nas curvas de cargas previstas, por exemplo, incrementos ou decrementos na curva ou em parte dela para ajustes finos ou, em casos específicos, para atender solicitações da programação com o objetivo de minimizar riscos energéticos e/ou elétricos do sistema.

Além disso, a planilha facilita a visualização dos resultados da tomada de decisão e executa rotinas em *Visual Basic for Application* (VBA) para automatizar tarefas como, importação e exportação de séries temporais, cargas previstas e cálculos diversos.

Na tomada de decisão, os resultados dos modelos ANNSTLF, CEPEL e ONS, são comparados com as curvas de carga verificadas selecionadas do histórico, de acordo com a decisão do analista responsável, para servir como referência. Essa seleção leva em consideração dias semelhantes, ou seja, dias de natureza semelhante com temperaturas previstas para o dia da operação similares às temperaturas verificadas nas datas selecionadas. Além das curvas de referência, a curva de carga verificada no dia atual (mesmo que ainda incompleta) também é considerada nessa análise.


6 DESCRIÇÃO DA METODOLOGIA

O objetivo deste trabalho, além de apresentar uma revisão da literatura sobre a análise e para a previsão de carga do SIN, é realizar um estudo de caso focado na previsão de carga para a hora subsequente do subsistema do Sul do Brasil usando LSTM/RNN.

Neste contexto, três etapas são construídas para obter o modelo de previsão. As etapas são ilustradas na Figura 10 e serão explicadas nos próximos tópicos:

- a) etapa 1: dados históricos e calendário civil;
- b) etapa 2: selecionar e calibrar o modelo;
- c) etapa 3: métricas de avaliação.

Figura 10 - Etapas da metodologia.



Fonte: Elaboração própria (2023).

6.1 Dados históricos e calendário civil

O conjunto de dados utilizados como entradas do modelo de previsão proposto são: dados históricos de carga global horária, que representa o perfil de consumo de energia elétrica; e o histórico de temperatura equivalente para o

subsistema, também com base horária. Estes dados são disponibilizados diariamente pelo ONS, através do portal SINtegre (ONS, 2023).

Além dos dados de carga e temperatura, também serão considerados os feriados nacionais, como uma variável adicional no modelo de previsão proposto. A inclusão dos feriados nacionais é importante, pois esses eventos podem afetar significativamente o consumo de energia elétrica, como variações no padrão de carga durante esses períodos específicos.

A análise das séries temporais de carga e temperatura, juntamente com a consideração dos feriados nacionais, pode fornecer *insights* valiosos para compreender o comportamento do consumo de energia elétrica e auxiliar nas tomadas de decisão relacionadas ao gerenciamento do sistema elétrico.

Esta etapa da metodologia, consiste na obtenção, exploração e processamento dos dados. A exploração dos dados de cargas e temperatura permite uma análise aprofundada do comportamento e das relações entre essas variáveis ao longo do tempo. Esses dados proporcionam percepções importante para as tomadas de decisão. Além disso, analisando as séries temporais de carga, é possível identificar padrões e tendências ao longo do ano.

6.2 Calibração do modelo neural

Para organização e análise dos dados de entrada, utilizou-se linguagem de programação *Python*. Os arquivos são armazenados em um ambiente de nuvem (*Google Drive*), permitindo que sejam acessados pelo algoritmo. Esse algoritmo é executado utilizando a ferramenta gratuita *Google Colaboratory*, que é um ambiente de *notebooks Python* executado em computadores na nuvem.

As bibliotecas utilizadas para a análise dos dados e modelagem do modelo de previsão foram: *numpy*, *pandas*, *tensorflow*, *matplotlib.pyplot* e dos seguintes frameworks *scikit-learn*: *MinMaxScaler*, *train_test_split*, *r2_score*, *mean_absolute_percentage_error*. A seguir uma breve explicação de cada uma (PYTHON, 2023).

Numpy é uma biblioteca fundamental para computação numérica em *Python*. Ela fornece uma estrutura de dados para manipular e operar com *arrays* multidimensionais, bem como funções matemáticas para realizar cálculos numéricos.

Pandas é uma biblioteca usada para manipular e analisar dados. Ela fornece estruturas de dados flexíveis, como o *Data Frame*, que permite organizar e manipular dados de forma tabular. Também possui uma ampla gama de funções para filtrar, limpar, transformar e visualizar dados.

Tensorflow é uma biblioteca de código aberto para aprendizado de máquina e IC. Ela oferece uma ampla gama de ferramentas e recursos para criar e treinar modelos de *machine learning*, especialmente modelos de redes neurais. Além disso, permite trabalhar com tensores (estruturas multidimensionais semelhantes a *arrays*) e oferece uma sintaxe para construir, treinar e avaliar modelos.

MinMaxScaler pertence ao módulo *sklearn.preprocessing*, é uma classe da biblioteca *scikit-learn* (*sklearn*) usada para realizar a normalização de dados. O *MinMaxScaler* redimensiona os valores dos dados para um intervalo específico, geralmente entre 0 e 1, mantendo a proporção entre os valores originais.

Train_test_split pertence ao módulo *sklearn.model_selection* é uma função do *scikit-learn* usada para dividir um conjunto de dados em subconjuntos de treinamento e teste. Essa função permite que especifique a proporção do conjunto de teste e também permite embaralhar os dados antes da divisão.

Matplotlib.pyplot é uma biblioteca de visualização em *Python* amplamente utilizada para criar gráficos e plotagens. Ela fornece uma ampla gama de funções para criar gráficos de linhas, dispersão, histogramas, barras, entre outros.

r2_score e *mean_absolute_percentage_error* do módulo *sklearn.metrics*, são funções do *scikit-learn* usadas para calcular o coeficiente de determinação (R^2) e o erro percentual médio absoluto, respectivamente. Essas métricas são comumente usadas para avaliar a qualidade de modelos de previsão.

O modelo LSTM desenvolvido é composto por três camadas: uma camada LSTM, uma camada oculta e uma camada de saída. Para este trabalho optou-se em utilizar *sigmoid* como função de ativação da camada LSTM e *relu* para a camada densa intermediária.

Para este modelo utiliza-se uma arquitetura de sequência-sequência. Essas camadas são adicionadas ao modelo sequencial na ordem em que são fornecidas. “O modelo sequencial permite inserir camadas de uma rede neural em série, onde o *output* da primeira camada serve como *input* da segunda, e assim por diante”(ROCHA, 2018).

Para prever a carga diária, foram testadas 16 arquiteturas diferentes da rede LSTM. A busca exaustiva foi realizada variando o número de neurônios nas camadas ocultas, com incrementos de 25 neurônios, dentro do intervalo de 20 a 95. Cada uma das 16 arquiteturas foi avaliada para determinar qual delas proporcionava os melhores resultados de previsão.

Além dos números de neurônios, outros parâmetros são necessários: otimizador, métrica de avaliação da função de perda, *batch size*, taxa de aprendizado, *epochs*.

O otimizador é responsável por minimizar o erro entre os resultados previstos pela rede e os resultados desejados. Em termos simples, quanto menor for o erro obtido pela rede neural, maior será a precisão dos resultados e, portanto, melhor será o desempenho da rede (RIBEIRO; ARAUJO JUNIOR, 2020). Para este trabalho optou-se por utilizar o otimizador *Adaptive Moment Estimation* (ADAM).

Segundo Kingma e Lei ba (2014), ADAM é um método de otimização que calcula taxas de aprendizado adaptativas individuais para cada parâmetro baseado nas estimativas dos gradientes. O objetivo é melhorar o processo de convergência do modelo, adicionando momento ao processo de atualização de pesos, reduzindo ou aumentando sua intensidade quando necessário (BONVICINE, 2021).

A função de perda, conforme foi elucidada na seção 4.1.3, deve ser minimizada, assim a métrica para esta função foi a *Mean Absolute Error* (MAE). Esta métrica calcula a média da diferença absoluta entre os valores previstos pelo modelo e os valores observados.

Batch size, define o tamanho do lote utilizado durante o treinamento. O conjunto de dados é dividido em lotes e o modelo é atualizado a cada lote. No final do lote, as previsões são comparadas às variáveis de saída esperadas e um erro é calculado. Com base nesse erro, é utilizado um o algoritmo de atualização para melhorar o modelo (VIEIRA, 2022).

A quantidade de *epoch* (época) determina quantas vezes o algoritmo de aprendizado percorrerá todo o conjunto de dados de treinamento. Uma época pode ser composta por um ou mais lotes, permitindo que cada amostra no conjunto de dados de treinamento atualize os parâmetros do modelo pelo menos uma vez (VIEIRA, 2022).

A taxa de aprendizado é um parâmetro ajustável utilizado no treinamento de RNAs, normalmente tendo um valor pequeno dentro do intervalo de 0 e 1. Ele controla a velocidade com que o modelo se ajusta ao problema. Taxas de aprendizado mais baixas exigem um número maior de épocas para convergir, pois fazem ajustes de peso menores a cada atualização. Por outro lado, taxas de aprendizado mais altas levam a mudanças mais rápidas e requerem menos iterações de treinamento para atingir a convergência (GÉRON, 2019; MATTMANN, 2021).

Esses parâmetros foram estabelecidos após várias iterações de treinamento, encontrando os valores que proporcionavam melhores resultados. Os valores encontrados são apresentados na Tabela 1.

Tabela 1 - Parâmetros adotados para o modelo LSTM/RNN.

Otimizador	Adam (<i>Adaptive Moment Estimation</i>)
Função de perda	MAE (Erro Médio Absoluto)
<i>Batch size</i>	512
Taxa de aprendizado	0,001
<i>Epochs</i>	100

Fonte: Elaboração própria (2023).

6.3 Métricas de Avaliação

O melhor modelo de previsão para uma série temporal é aquele que minimiza os erros entre os valores previstos e os valores reais. Para avaliação do desempenho do modelo, comparou-se estes valores. Nas Equações 1-2, n é o número de observações total da série temporal, $\hat{y}_t$ representa os valores previstos, y_t os reais medidos e $\bar{y}_t$ o valor médio de y_t .

Erro percentual absoluto médio (MAPE, *mean absolute percentage error*)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| * 100 \quad (1)$$

O índice acima é métrica de imprecisão, porém não fornecem uma indicação clara de quão bem um modelo se adaptou a um conjunto de dados. Portanto, neste estudo, também foi empregado o coeficiente de determinação R^2 . Este coeficiente, reflete a proporção da variação nos dados que é atribuída ao modelo. Os resultados oscilam entre 0 e 1 e são frequentemente apresentados em formato percentual, variando de 0% a 100%. Quanto maior for o valor de R^2 , mais o modelo é capaz de explicar as variações nos dados previstos.

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

7 ESTUDO DE CASO

Para estimar a carga elétrica do Subsistema Sul, foram empregadas as metodologias delineadas na seção anterior. A série temporal considerada é do período de 01 de janeiro de 2014 à 31 de dezembro de 2021, totalizando em 70128 dados. Sendo que 80% dos dados serão utilizados para treino e 20% para validação do modelo.

A porcentagem de dados a serem usados para validação em um modelo de previsão de séries temporais deve variar dependendo do tamanho do conjunto de dados disponível, da complexidade do problema e de quanto tempo adiante deseja-se fazer a previsão. A proporção 80x20 é muito utilizada na literatura (GÉRON, 2019; VIEIRA, 2022).

Diferente dos métodos de classificação e regressão sem a influência do tempo, em séries temporais não se pode dividir os dados de treino e teste com amostras aleatórias de qualquer parte dos dados, deve-se seguir o critério temporal da série, onde os dados de treino devem vir antes dos dados de teste (RABELO, 2019).

Durante o período considerado, foram identificados um total de 96 dias de feriados nacionais brasileiros. Esses feriados abrangem datas como a Confraternização Universal, as Segunda e Terça-feira de Carnaval, a Paixão de Cristo, o Dia de Tiradentes, o Dia do Trabalho, *Corpus Christi*, a Independência do Brasil, a celebração de Nossa Senhora Aparecida - Padroeira do Brasil, o Dia de Finados, a Proclamação da República e o Natal.

Identificar as tendências sazonais, flutuações diárias e anomalias é crucial para que o modelo tenha o melhor desempenho. É necessário analisar os dados de entrada e verificar seus parâmetros gerais. Apesar dos dados de entrada serem processados pelo ONS, é necessário realizar pequenos ajustes, uma vez que a base de dados utilizada foi inicialmente preparada para ser empregada em uma metodologia diferente.


7.1 Dados Históricos - Obtenção, Exploração e Processamento dos Dados

Optou-se por utilizar os dados de carga global para todo o subsistema sul, sem distinção quanto a tipologia de consumo. Estes dados são disponibilizados diariamente pelo ONS, através do portal SINtegre (ONS, 2023). Dentre dos dados de carga, identificou-se uma inconsistência em um ponto específico: no dia 24-09-2016 às 00:00, foi observado um valor anormalmente elevado e negativo. A fim de manter a integridade dos dados e garantir a confiabilidade da análise, decidiu-se remover esse dado inconsistente e substituí-lo pela média dos valores da hora anterior e posterior a esse ponto.

Optou-se por utilizar os dados de temperatura média de toda a região sul do Brasil. Os dados de temperatura foram obtidos da mesma fonte dos dados de consumo, o SINtegre (ONS, 2023). Uma análise semelhante foi realizada para os dados de temperatura. Não se encontrou nenhuma inconsistência nos dados, no entanto, identificou-se que havia registros em branco nos dias 19-10-2014, 18-10-2015, 16-10-2016, 15-10-2017 e 04-11-2018, todos no mesmo horário, às 01:00. Assim como feito para dos dados de carga, optou-se por substituir esses valores em branco pela média das temperaturas da hora anterior e posterior a esses pontos.

Ambas as series apresentam comportamentos sazonais. Tal comportamento pode ser observado Figura 11.


Figura 11 - Série Temporal da Carga e Temperatura ao Longo dos Anos.



Fonte: Elaboração própria (2023).

Note, as séries temporais apresentam picos altos no início de cada ano e decresce no seu decorrer. Este comportamento fica mais evidente na Figura 12.


Figura 12 - Variação Média da Carga e da Temperatura Mensal ao Longo do Tempo.



Fonte: Elaboração própria (2023).

O gráfico ilustrado na Figura 13 representa a relação entre a carga e a temperatura. Cada ponto no gráfico representa uma observação de carga e temperatura em um determinado momento. Percebe-se que há uma correlação entre a carga e a temperatura. Note que há uma relação de aumento da carga à medida que a temperatura aumenta. Uma análise de interpolação quadrática foi realizada para estimar os valores intermediários entre os pontos observados, fornecendo uma visualização mais completa e precisa do comportamento dessas variáveis.


Figura 13 - Tendência de Crescimento.



Fonte: Elaboração própria (2023).

A Figura 14 apresenta a carga média em MWm ao longo do período considerado.

Figura 14 - Carga Média Histórica Anual.



Fonte: Elaboração própria (2023).

Percebe-se que, após o ano de 2014, houve uma retração no crescimento da carga. Tal retração deve-se a crise econômica que assolou o país. Após apresentar um ligeiro crescimento em 2014, com um aumento real de 0,5% no PIB (Produto Interno Bruto), a economia sofreu uma contração de 3,8% em 2015 e de 3,6% em 2016 (PAULA, 2019). Essa recessão foi uma das piores da história brasileira e gerou amplas discussões sobre suas causas.

Dentro desses debates, há uma parte que atribui grande parte da responsabilidade aos fatores internos, em particular, às políticas adotadas durante o governo Dilma Rousseff, conhecidas como "Nova Matriz Macroeconômica" (PAULA, 2019). Essa abordagem macroeconômica adotada durante esse período foi criticada por sua ênfase em estímulos fiscais e controle de preços, o que levou a desequilíbrios econômicos e ao aumento da inflação, que por consequência influenciou no crescimento da carga.


Além da crise econômica, o Brasil também enfrentou uma crise hídrica entre agosto de 2020 e setembro de 2021. Nesse período, os reservatórios do Sudeste

e Centro-Oeste, que representam cerca de 70% do armazenamento de água do país, atingiram níveis mínimos históricos, com apenas 26% de capacidade (SANTOS; FIGER, 2022). Essa escassez hídrica teve impactos significativos na economia, afetando a geração de energia.

Neste mesmo período, o país enfrentava a pandemia da COVID-19 e suas decorrentes medidas de isolamento social geraram impactos negativos na carga de energia, principalmente a partir do mês de abril. As classes comercial e industrial foram as mais impactadas. Por outro lado, a classe residencial teve reflexo positivo por conta do confinamento (EPE, 2020).

A carga anual média é uma medida que representa a demanda média de energia ao longo de cada ano. Embora seja possível obter algumas informações sobre os padrões de consumo, há limitações em tirar conclusões definitivas com base nesses dados isoladamente. Por isso, uma abordagem mais detalhada foi adotada, gerando um gráfico que mostra a carga média mensal *versus* a temperatura média mensal, que pode ser vista na Figura 15. A análise da carga média mensal oferece *insights* sobre a sazonalidade da demanda, mostrando como a carga varia de acordo com as estações do ano. Nota-se que há baixa demanda no inverno e alta demanda no verão, características de uma região onde o clima predominante é o subtropical.

Figura 15 - Carga Média x Temperatura Média - Mensal.




Fonte: Elaboração própria (2023).

Além da análise do comportamento da carga ao longo dos meses, deve-se observar também, a carga média semanal, pois destaca padrões de consumo ao longo

da semana, revelando variações entre dias úteis e finais de semana. A Figura 16 apresenta este comportamento.


Figura 16 - Carga Média Histórica Semanal.



Fonte: Elaboração própria (2023).

Por fim, a carga horária média é apresentada na Figura 17. As variações da demanda de energia ao longo do dia revelam os períodos de pico e de menor consumo durante as 24 horas, destacando os momentos em que o sistema elétrico é mais exigido.

Figura 17 - Carga Média Horária.



Fonte: Elaboração própria (2023).

A correlação entre as séries temporais da carga e da temperatura é outro aspecto importante a ser considerado. Ela permite identificar a influência que as variações de temperatura exercem sobre a demanda de energia. Uma forma de mensurar a correlação entre duas variáveis é a correlação *Person* e a correlação de *Spearman*, os quais variam entre -1 e +1 e não dependem das unidades de medida das variáveis, o que facilita a sua interpretação (GALARÇA *et al.*, 2010; SOUZA, 2019; GÉRON, 2019).

O coeficiente de correlação de *Pearson* é adequado para medir relações lineares entre variáveis. O valor de zero indica que não há relação linear entre as variáveis. Quanto mais próximo de 1 (em valor absoluto), mais forte é a relação linear entre elas. O sinal do coeficiente indica a direção da relação: um valor positivo significa que as variáveis aumentam ou diminuem juntas, enquanto um valor negativo indica que elas variam em direções opostas (SOUZA, 2019).

Por outro lado, o coeficiente de *Spearman* avalia a intensidade e o sentido de uma relação monótona entre duas variáveis, desde que pelo menos estejam em uma escala ordinal. Esse coeficiente leva em consideração a ordem dos valores observados, em vez dos próprios valores originais. Ele pode ser aplicado tanto a dados lineares quanto a dados não lineares (SOUZA, 2019).

Através do gráfico ilustrado na Figura 13, é observado que a relação entre a carga e a temperatura é não linear. Contudo, há uma linearidade entre estes valores uma vez que a carga aumenta à medida que há um aumento de temperatura. Por isso, foi calculado a correlação entre a carga e a temperatura para o subsistema sul utilizando os dois coeficientes. Os valores obtidos são apresentados na Tabela 2.

Tabela 2 - Valores de Correlação de *Pearson* e *Spearman* entre Variáveis.

Correlação de <i>Spearman</i>	0.460377177
Correlação de <i>Person</i>	0.472120461

Fonte: Elaboração própria (2023).

Segundo Souza (2019), se os valores dos coeficientes de correlação de *Pearson* e *Spearman* forem semelhantes, isso indica que provavelmente existe uma relação linear entre as variáveis. No entanto, se o valor do coeficiente de correlação de *Spearman* for maior do que o de *Pearson*, é provável que haja uma relação não

linear e monotônica entre as variáveis. Por outro lado, se o valor do coeficiente de correlação de *Pearson* for maior do que o coeficiente de correlação de *Spearman*, isso pode ser devido à presença de outliers, o que pode influenciar a análise da relação entre as variáveis.

Os valores obtidos foram semelhantes, logo há uma relação de linearidade entre as variáveis. Contudo, o valor obtido para os coeficientes foi próximo de 0.47. Esse valor indica uma correlação positiva fraca a moderada. Embora não seja uma correlação muito forte, ainda é suficiente para demonstrar numericamente a existência de uma relação positiva entre as variáveis. Isso significa que há uma tendência para que a carga e a temperatura aumentem ou diminuam juntas.

Cabe aqui refletir que se está trabalhando com a carga global para o subsistema sul, sem distinção do tipo de consumo como por exemplo industrial, comercial ou residencial. Também o uso da temperatura média para uma região onde existem distintos comportamentos meteorológicos e climatológicos pode não ser a mais adequada. Estudos do Grupo de Pesquisa em Computação Científica para a Engenharia (PECCE) em conjunto com o Laboratório de Redes Elétricas Inteligentes (LABSMART) demonstram que existe forte correlação entre a temperatura e o consumo de energia elétrica do tipo residencial e comercial (FERREIRA *et al.*, 2023). Essa tipificação da carga não faz parte do escopo deste TCC. Acredita-se que o consumo industrial seja bem menos influenciado pela temperatura ambiente, e por ser maior do que os demais tipos de consumo, acaba por reduzir a correlação entre consumo e temperatura.

7.2 Resultados e discussões

A rede foi ajustada conforme os parâmetros da Tabela 1 e os resultados são apresentados na Tabela 3.

Tabela 3 - Resultados obtidos para as 16 configurações de arquiteturas da RNN-LSTM para a previsão da carga diária - Subsistema Sul.


Índice	Camada LSTM	Camada Oculta	R2	MAPE (%)
1	20	20	0,946752	2,8204%
2	20	45	0,946768	2,8727%
3	20	70	0,936888	3,0321%
4	20	95	0,945949	3,2502%
5	45	20	0,932993	3,1513%
6	45	45	0,948836	2,7237%
7	45	70	0,941689	2,8571%
8	45	95	0,948261	2,7365%
9	70	20	0,936752	3,0982%
10	70	45	0,948315	2,8399%
11	70	70	0,923573	3,4630%
12	70	95	0,947245	2,7208%
13	95	20	0,918595	4,4477%
14	95	45	0,944660	2,9245%
15	95	70	0,954060	2,5893%
16	95	95	0,946412	2,7739%

Fonte: Elaboração própria.

Para as 16 arquiteturas foram encontrados resultados satisfatórios. Com erros Mape abaixo de 5% e coeficiente R2 acima de 0,91. A configuração que apresentou o melhor resultado é constituído por 95 neurônios na camada LSTM e 70 neurônios na camada oculta.


Para esta configuração foi gerada a curva de carga prevista *versus* a curva de carga real para diferentes datas, abrangendo diferentes cenários, como dias de semana, feriados, finais de semana e dias quentes. O objetivo principal dessa análise foi comparar o desempenho do modelo utilizado para realizar as previsões.

Figura 18- Previsão de carga diária Segunda-Feira - 01 de junho de 2020.




Fonte: Elaboração própria (2023).

Figura 19 - Previsão de carga diária Domingo – 20 de setembro de 2020.



Fonte: Elaboração própria (2023).


Figura 20 - Previsão de carga diária Feriado Nacional – 25 de dezembro de 2021.



Fonte: Elaboração própria (2023).

O dia mais quente do conjunto de dados testes, apresentou temperatura máxima de 33°C. Para esta data se obteve erro MAPE de 0,0399, como pode ser vista na Figura 21.

Figura 21 - Previsão de carga diária dia mais quente dos dados testes – 25 de novembro de 2020.




Fonte: Elaboração própria (2023).

Com base nas representações gráficas apresentadas, pode-se depreender que o modelo utilizado demonstrou um bom ajuste e desempenho satisfatório para os dias de semana. No entanto, este cenário em comparação aos demais, o modelo não

conseguiu realizar previsões precisas. Isso indica que o modelo não foi capaz de capturar flutuações e comportamentos irregulares na demanda de energia.


Para cada arquitetura também foi avaliado a função perda através do gráfico *loss* por *Epoch*. Conforme pode ser vista nas Figuras Figura 22 - Figura 25. Estes gráficos mostram as curvas de aprendizado *training loss* e *validation loss*. A curva de aprendizado *training loss* é calculada a partir do conjunto de dados de treinamento, dá uma ideia de quão bem o modelo está aprendendo. Já a curva de aprendizado *validation loss* é calculada a partir do conjunto de dados teste (validação) e fornece uma estimativa de como o modelo está generalizando para novos dados.

Figura 22 - Loss function arquitetura 1-4.




Fonte: Elaboração própria.

Figura 23 - Loss function arquitetura 5-8.




Fonte: Elaboração própria.

Figura 24 - Loss function arquitetura 9-12.



Fonte: Elaboração própria.

Figura 25 - Loss function arquitetura 13-16.




Fonte: Elaboração própria.

Segundo Brownlee (2019), existem quatro comportamentos comuns que podem ser observados nas curvas de aprendizado: *underfitting*, *overfitting*, *good fit* e conjuntos de dados não representativos.

Underfitting (subajustado) refere-se a um modelo que não consegue aprender o conjunto de dados de treinamento. Este comportamento pode ser identificado a partir da curva de aprendizado *training loss*. Um gráfico de curvas de aprendizado mostra-se *underfitting* quando apresenta uma linha plana ou valores ruidosos de perda relativamente alta (indicando que o modelo não foi capaz de aprender o conjunto de dados de treinamento) ou quando a perda de treinamento que está diminuindo e continua diminuindo no final do gráfico. A Figura 26 ilustra exemplos destes dois possíveis comportamentos.


Figura 26 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo subajustado.



Fonte: Brownlee (2019).

Overfitting (sobreajuste) refere-se a um modelo que aprendeu muito bem o conjunto de dados de treinamento, incluindo o ruído estatístico ou flutuações aleatórias. Contudo, não generaliza muito bem para novos dados, resultando em um aumento no erro de generalização (GÉRON, 2019). Esse aumento no erro de generalização pode ser medido pelo desempenho do modelo no conjunto de dados de teste. “Uma maneira de melhorar um modelo de sobreajuste é alimentá-lo com mais dados de treinamento até que o erro de validação atinja o erro de treinamento” (GÉRON, 2019). Um gráfico de curvas de aprendizado mostra-se *overfitting* (Ver Figura 27) quando a curva de aprendizado *training loss* continua a diminuir e quando curva de aprendizado *validation loss* diminui até certo ponto e começa a aumentar novamente.


Figura 27 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo sobreajustado.



Fonte: Brownlee (2019).

O *good fit* é identificado por uma perda de treinamento e validação que diminui até um ponto de estabilidade com um intervalo mínimo entre os dois valores finais de perda. A perda do modelo quase sempre será menor no conjunto de dados de treinamento do que no conjunto de dados de teste (BROWNLEE, 2019). Isso significa que deve apresentar lacuna entre as curvas de aprendizado de perda de treinamento e validação. Essa lacuna é chamada de “lacuna de generalização”. Este comportamento pode ser observado na Figura 28.


Figura 28 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando um modelo *good fit*.



Fonte: Brownlee (2019).

Um conjunto de dados de treinamento não representativo significa que o conjunto de dados de treinamento não fornece informações suficientes para aprender o problema, em relação ao conjunto de dados de validação usado para avaliá-lo. Isso pode ocorrer se o conjunto de dados de treinamento tiver poucos exemplos em comparação com o conjunto de dados de validação. Também pode ser identificado por uma perda de validação menor que a perda de treinamento. E em casos onde a curva de aprendizado para perda de treinamento parece ter um bom ajuste uma curva de aprendizado para perda de validação que mostra movimentos ruidosos em torno da perda de treinamento. A Figura 29 ilustra comportamentos das curvas para um conjunto de dados não representativos.

Figura 29 - Exemplo de gráfico de função de perdas com curva de aprendizado mostrando conjunto de dados de treinamento não representativo



Fonte: Brownlee (2019).

Comparando os gráficos obtidos com os comportamentos citados acima, pode-se aferir que não houve casos de *Underfitting*. As configurações 3 e 4 apresentaram comportamento de que o conjunto de dados de treinamento é não representativo (Ver Figura 22). Para as demais arquiteturas, percebe-se que teve um bom ajuste. Contudo, apresenta pequenos picos o que pode indicar que o modelo está começando a sofrer *overfitting*, apesar da curva de aprendizado *validation loss* não ter diminuído até um certo momento e começar a aumentar novamente (Ver Figura 22 e Figura 25).

8 CONCLUSÃO FINAL

O presente Trabalho de Conclusão de Curso de graduação em Engenharia Elétrica desenvolveu uma metodologia para previsão de carga de curto prazo (dia seguinte) para o subsistema sul do Brasil. A abordagem computacional utilizada foi a RNN/LSTM. Os dados de entrada do modelo são os feriados nacionais, a temperatura ambiente e o histórico de consumo de energia elétrica na região. Todo o banco de dados é de acesso público e gratuito.

Foram testadas 16 arquiteturas diferentes para RNN/LSTM, variando o número de neurônios nas camadas ocultas em incrementos de 25, dentro do intervalo de 20 a 95. Todas as arquiteturas apresentaram bom desempenho, abaixo dos 5% de erro na previsão, o que sugere que a técnica de LSTM é adequada para esse tipo de previsão. A melhor arquitetura encontrada consistiu em uma LSTM com 95 neurônios e uma camada oculta com 70 neurônios. Essa configuração específica proporcionou os melhores resultados, com um erro MAPE de 2,58% e um coeficiente R^2 de 0,95.

A utilização do *Google Colab* como plataforma demonstrou eficiência durante o processo de previsão. Não ocorreram interrupções e o tempo de execução foi rápido. Além disso, a biblioteca *TensorFlow* oferece uma variedade de níveis de abstração, permitindo escolher aquele que melhor se adequa às necessidades, o que facilitou o treinamento e a implementação do modelo, sem comprometer a velocidade ou o desempenho.

Os resultados são encorajadores. Eles sugerem que a utilização de modelos baseados em LSTM, juntamente com os dados adequados, pode ser uma abordagem eficaz para previsões de carga a curto prazo. No entanto, é importante ressaltar que esse estudo se concentrou apenas no subsistema sul do Brasil e que os resultados podem variar em outras regiões. Também há que se refletir sobre a não tipificação da carga e o uso da temperatura média para toda a região. Incorporar tais aspectos deve melhorar ainda mais a acurácia da previsão.

Por fim, lembra-se que o presente trabalho é acadêmico, limitado em tempo e escopo. O objetivo foi a resolução de um exercício simplificado para previsão de carga de forma direta. O planejamento para a operação do subsistema do SIN pela

ONS leva em conta diversos outros fatores além da previsão da carga, bem como a própria previsão deve considerar outros aspectos dada complexidade da operação.

8.1 Sugestões para trabalhos futuros

- a) Experimentar diferentes valores para os parâmetros do modelo, como o número de neurônios nas camadas ocultas, as taxas de aprendizado e o número de épocas de treinamento;
- b) Explorar diferentes arquiteturas de rede neural;
- c) Considerar técnicas adicionais de pré-processamento de dados, como normalização diferente (por exemplo, normalização por grupo), codificação de variáveis categóricas ou remoção de outliers;
- d) Realizar exercícios de previsão para cada tipo de carga (industrial, comercial e residencial);
- e) Utilizar um conjunto de dados com um maior histórico;
- f) Realizar exercícios com abrangência territorial menor, de forma que a temperatura média seja mais representativa;
- g) Explorar a inclusão de outras variáveis nos dados de entrada do modelo. Por exemplo, adicionar informações climáticas como precipitação e humidade;
- h) Buscar fazer um comparativo de previsões de carga entre os subsistemas;
- i) Além das métricas de desempenho padrão utilizada, explore métricas adicionais, como erro quadrático médio (MSE) e erro absoluto médio (MAE) para ter uma visão mais abrangente do desempenho do modelo;
- j) Realizar previsões com diferentes horizontes de tempo. Isso permitirá uma compreensão mais completa das tendências e padrões de demanda de energia em diferentes escalas temporais.

REFERÊNCIAS

ALMESHAEI, Eisa; SOLTAN, Hassan. A methodology for Electric Power Load Forecasting. **Alexandria Engineering Journal**, Mansoura, v. 50, n. 2, p. 137–144, 2011. DOI: 10.1016/J.AEJ.2011.01.015.

ANDRADE FILHO, A. P. EMPREGO DE REDES NEURAIAS LSTM NA PREDIÇÃO DE SÉRIES TEMPORAIS APLICADAS AO CONSUMO DE ENERGIA ELÉTRICA. **CEEL**, [S. l.], p. 1–6, 2021. Disponível em: https://www.peteletricaufu.com.br/static/ceel/artigos/artigo_625.pdf. Acesso em: 6 maio. 2023.

AOYANG, Han; SHENGQI, Zhou; QINGDAO, Jian Xuehui; ZHISHENG, Zhang. Short-term Load Forecasting Model Based on RBF Neural Network Optimized by Artificial Bee Colony Algorithm. **Anais** [...]. Nanchang: IEEE, 2021. p. 486–489. DOI: 10.1109/ICBAIE52039.2021.9390043. Disponível em: <https://ieeexplore.ieee.org/document/9390043>. Acesso em: 21 jan. 2022.

ANACE. ASSOCIAÇÃO NACIONAL DOS CONSUMIDORES DE ENERGIA. **Grandes apagões viram rotina no Brasil**. 2022. Disponível em: <http://www.anacebrasil.org.br/noticias/grandes-apagoes-viram-rotina-no-brasil/>. Acesso em: 18 fev. 2022.

AYDAROUS, Amr A.; ELSHAHED, Mostafa. A.; MOUSTAFA HASSAN, M. A. Short-Term Load Forecasting Approach Based on Different Input Methods of One Variable: Conceptual and Validation Study. 2018. Cairo. **Anais** [...]. Cairo: IEEE, 2018. p. 179–184. DOI: 10.1109 / MEPCON.2018.8635115. Disponível em: <https://ieeexplore.ieee.org/document/8635115/>. Acesso em: 26 jan. 2022.

AZIZ, Mustafa Nizamul; LECTURER, Senior. A Review on Artificial Neural Networks and its' Applicability. **Bangladesh Journal of Multidisciplinary Scientific Research**, [S. l.], v. 2, p. 1–4, 2020. Disponível em: <https://www.cribfb.com/journal/index.php/BJMSR/article/view/609/799>. Acesso em: 23 abr. 2023.

BARROS, Anna Carolina; MATTOS, Daiane Marcolino; OLIVEIRA, Ingrid Christyne Luquett; FERREIRA, Pedro Guilherme Costa; DUCA, Victor Eduardo Leite de Almeida. **Análise de Séries Temporais em R: Curso Introductório**. 1. ed.Elsevier, 2017. Disponível em: <https://app.minhabiblioteca.com.br/#/books/9788595154902/>. Acesso em: 8 jun. 2023.

BASHARI, Masoud; RAHIMI-KIAN, Ashkan. Forecasting electric load by aggregating meteorological and history-based deep learning modules. **IEEE Power and Energy Society General Meeting**, Montreal, p. 0–4, 2020. DOI: 10.1109/PESGM41954.2020.9282124.

BASSO, Lucas Machado. **MODELO DE PREVISÃO DE DEMANDA DE ORDENS DE MANUTENÇÃO EMERGENCIAIS BASEADA EM FATORES CLIMÁTICOS EM UM SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**. 2020. Dissertação - UNIVERSIDADE FEDERAL DE SANTA MARIA, Santa Maria, 2020. Disponível em: https://repositorio.ufsm.br/bitstream/handle/1/21046/DIS_PPGEPP_2020_BASSO_LUCAS.pdf?sequence=1&isAllowed=y. Acesso em: 13 fev. 2022.

BENDAOUD, N. M. M.; FARAH, N.; BEN AHMED, S. Applying load profiles propagation to machine learning based electrical energy forecasting. **Electric Power Systems Research**, [S. l.], v. 203, p. 2–14, 2022. DOI: 10.1016/j.epsr.2021.107635.

BICHELS, Arlei. **Sistemas elétricos: métodos de análise e solução**. Curitiba.

BONVICINE, Angelo Antonio de Carvalho. **Previsão de carga para a programação diária eletroenergética do sistema interligado nacional por redes neurais artificiais**. 2021. Monografia - UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”, Ilha Solteira, 2021. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/213945/bonvicine_aac_tcc_ilha.pdf?sequence=6. Acesso em: 27 maio. 2023.

BROWNLEE, Jason. **Multivariate Time Series Forecasting with LSTMs in Keras**. 2017. Disponível em: <https://machinelearningmastery.com/multivariate-time-series-forecasting-lstms-keras/>. Acesso em: 10 jun. 2023.

BROWNLEE, Jason. **How to use Learning Curves to Diagnose Machine Learning Model Performance**. 2019. Disponível em:

<https://machinelearningmastery.com/learning-curves-for-diagnosing-machine-learning-model-performance/>. Acesso em: 15 jun. 2023.

BUI, The Duy; NGUYEN, Duy Khuong; NGO, Tien Dat. Supervising an unsupervised neural network. **Proceedings - 2009 1st Asian Conference on Intelligent Information and Database Systems, ACIIDS 2009**, [S. l.], p. 307–312, 2009. DOI: 10.1109/ACIIDS.2009.92. Acesso em: 13 maio. 2023.

CHEN, Ning; LIU, Wenjing; BAI, Ruizhen; CHEN, An. Application of computational intelligence technologies in emergency management: a literature review. **Artificial Intelligence Review**, China, v. 52, n. 3, p. 2131–2168, 2019. DOI: 10.1007/S10462-017-9589-8/TABLES/5.

CRAENEN, Bart; ELBEN, A. E. Computational Intelligence. *Em*: **Encyclopedia of Life Support Sciences (EOLSS)**., 2002.

CUNHA JÚNIOR, Rubens Oliveira Da; FIRMINO, Paulo Renato Alves. APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DO NÍVEL DE ÁGUA SUBTERRÂNEA EM POÇO DE MONITORAMENTO NA BACIA SEDIMENTAR DO ARARIPE, CEARÁ. **Revista Geociências**, São Paulo, p. 427–431, 2022. Disponível em:

<https://www.periodicos.rc.biblioteca.unesp.br/index.php/geociencias/article/view/16103/12511>. Acesso em: 11 maio. 2023.

DANIEL CAMPOS; MANOEL MARINHO. Previsão de Poluentes Atmosféricos Utilizando Modelos Estatísticos de Regressão na Região Metropolitana do Recife. **Revista de Engenharia e Pesquisa Aplicada**, Recife, v. 4, n. 4, p. 11–18, 2019.

DEEP LEARNING BOOK. **Arquitetura de Redes Neurais Long Short Term Memory (LSTM)**. 2022. Disponível em:

<https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/>. Acesso em: 6 maio. 2023.

DEORAS, Ameya. **Electricity Load and Price Forecasting Webinar Case Study**. 2012. Disponível em: <https://nl.mathworks.com/matlabcentral/fileexchange/28684-electricity-load-and-price-forecasting-webinar-case-study>. Acesso em: 4 fev. 2022.

DISCONZI, Claudia Maria Dias Guerra. **PREVISÃO DOS PREÇOS DE COMMODITIES AGRÍCOLAS BRASILEIRAS NO MERCADO FUTURO**

UTILIZANDO REDES NEURAIIS ARTIFICIAIS. 2018. Dissertação - Universidade Federal do Pampa, Santana do Livramento, 2018. Disponível em: <https://dspace.unipampa.edu.br/bitstream/riu/2967/1/Claudia%20Guerra%20Disconzi%20-%202018.pdf>. Acesso em: 13 maio. 2023.

EPE. EMPRESA DE PESQUISA ENERGÉTICA. **BALANÇO COVID-19:** Impactos nos mercados de energia no Brasil. 2020. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-500/Balanco_Covid-19%20rev.pdf. Acesso em: 02 jul. 2023.

EPE. EMPRESA DE PESQUISA ENERGÉTICA. **Plano Decenal de Expansão de Energia.** 2021. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/plano-decenal-de-expansao-de-energia-pde>. Acesso em: 20 jan. 2022.

FERNANDES, Amanda Thais dos Reis; FONSECA, Jean Lucas Tourinho; SILVA, Iuri Leno Pereira Da; AGAMEZ ARIAS, Piedy Del Mar; RAMOS, Rodrigo Andrade; OLIVEIRA, Werbeston Douglas De. Avaliação da influência das tensões de barra na previsão de cargas via redes neurais. **Research, Society and Development**, [S. l.], v. 10, p. 1–13, 2021. DOI: 10.33448/rsd-v10i12.20917.

FERNEDA, Edberto. Redes neurais e sua aplicação em sistemas de recuperação de informação. **SciELO**, Brasília, p. 25–30, 2006. Disponível em: <https://www.scielo.br/j/ci/a/SQ9myjZWLxnyXfstXMgCdcH/abstract/?lang=pt>. Acesso em: 23 abr. 2023.

FERREIRA, ANDRÉIA BRASIL ALVES. **PREVISÃO DE CARGA MULTINODAL UTILIZANDO REDE NEURAL ARTMAP EUCLIDIANA.** 2020. Dissertação - UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO” FACULDADE DE ENGENHARIA CAMPUS DE ILHA SOLTEIRA, Ilha Solteira, 2020. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/193357/ferreira_aba_me_ilha.pdf?sequence=3&isAllowed=y. Acesso em: 17 nov. 2021.

FERREIRA, Greicili dos Santos; SANTOS, Deilson Martins Dos; AVILA, Sérgio Luciano; ALBANI, Vinicius Viana Luiz Albani; ORSI, Gustavo Cardoso; VIEIRA, Pedro Cesar Cordeiro; RODRIGUES, Rafael Nilson. Short- and long-term forecasting

for building energy consumption considering IPMVP recommendations, WEO and COP27 scenarios. **Applied Energy**, [S. l.], v. 339, p. 120980, 2023. DOI: 10.1016/J.APENERGY.2023.120980. Acesso em: 10 jun. 2023.

FLECK, Leandro; FERREIRA, Maria Hermínia; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. REDES NEURAIAS ARTIFICIAIS: PRINCÍPIOS BÁSICOS ARTIFICIAL. **Revista Eletrônica Científica Inovação e Tecnologia**, Paraná, v. 13, p. 47–57, 2016. . Acesso em: 23 abr. 2023.

FREITAS, Gabriela Carvalho; BRAGA, Nathalia Antunes Bedor. **Estudo de identificação de um reator de Van de Vusse com Redes Neurais Feedforward**. 2020. Monografia - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2020. Disponível em: <https://pantheon.ufrj.br/bitstream/11422/13442/1/GCFreitas.pdf>. Acesso em: 1 maio. 2023.

GALARÇA, Simone Padilha; LIMA, Cláudia Simone Madruga; SILVEIRA, Gustavo Da; RUFATO, Andreia de Rossi. Correlação de pearson e análise de trilha identificando variáveis para caracterizar porta-enxerto de *Pyrus communis* L. **Ciência e Agrotecnologia**, [S. l.], v. 34, n. 4, p. 860–869, 2010. DOI: 10.1590/S1413-70542010000400010. Disponível em: <https://www.scielo.br/j/cagro/a/QMy6pt47hzh6WcDdBJSvtzP/>. Acesso em: 10 jun. 2023.

GÉRON, Aurélien. **Mãos à Obra Aprendizado de Máquina com Scikit-Learn & TensorFlow: Conceitos, Ferramentas e Técnicas Para a Construção de Sistemas Inteligentes**. Alta Books Editora ed. Rio de Janeiro. Disponível em: www.altabooks.com.br.

GOLDSCHMIDT, Ronaldo Ribeiro Rio. **Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações**. 1º ed. Rio de Janeiro.

GUIRELLI, Cleber Roberto. **Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial**. 2006. TESE - Universidade de São Paulo, São Paulo, 2006. Disponível em: <https://teses.usp.br/teses/disponiveis/3/3143/tde-19042007-142653/pt-br.php%0Ahttp://www.teses.usp.br/teses/disponiveis/3/3143/tde-19042007-142653/>. Acesso em: 17 nov. 2021.

GUTIERREZ, JOSE LUIS CARRASCO. **MONITORAMENTO DA INSTRUMENTAÇÃO DA BARRAGEM DE CORUMBÁ I POR REDES NEURAIS E MODELOS DE BOX & JENKINS**. 2003. Dissertação - PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO, Rio de Janeiro, 2003. Acesso em: 9 jun. 2023.

HAYKIN, Simon. **Redes Neurais Princípios e prática**. 2. ed. [s.l: s.n.].

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. [s.l: s.n.].

Disponível em: <https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>. Acesso em: 23 abr. 2023.

HERNÁNDEZ, Gerardo. **Predicción de Precios y Carga de Electricidad con MATLAB**. 2013. Disponível em: <https://nl.mathworks.com/videos/electricity-load-and-price-forecasting-with-matlab-82037.html>. Acesso em: 4 fev. 2022.

HOCHREITER, Sepp; SCHMIDHUBER, Jurgen. Long Short-Term Memory. **Neural Computation**, [S. l.], p. 1–32, 1997. Disponível em:

<https://www.bioinf.jku.at/publications/older/2604.pdf>. Acesso em: 6 maio. 2023.

HU, Li; ZHANG, Lei; WANG, Tao; LI, Kai. Short-term load forecasting based on support vector regression considering cooling load in summer. **Proceedings of the 32nd Chinese Control and Decision Conference, CCDC 2020**, Hefei, p. 5495–5498, 2020. DOI: 10.1109/CCDC49329.2020.9164387.

JHA, Nishant; PRASHAR, Deepak; RASHID, Mamoon; GUPTA, Sachin Kumar; SAKET, R. K. Electricity load forecasting and feature extraction in smart grid using neural networks. **Computers & Electrical Engineering**, India, v. 96, p. 107479, 2021. DOI: 10.1016/J.COMPELECENG.2021.107479.

JÚNIOR, JOAQUIM RIBEIRO MOREIRA. **PREVISÃO DE CARGAS MULTINODAIS REALIZADA ATRAVÉS DA ANÁLISE DA PREVISÃO DE CARGAS ELÉTRICAS AGREGADAS VIA REDE NEURAL ARTMAP FUZZY**. 2020. Dissertação - Universidade Estadual Paulista Julio de Mesquita Filho, Ilha Solteira, 2020.

KHWAJA, A. S.; ZHANG, X.; ANPALAGAN, A.; VENKATESH, B. Boosted neural networks for improved short-term electric load forecasting. **Electric Power Systems Research**, Toronto, v. 143, p. 431–437, 2017. DOI: 10.1016/J.EPSR.2016.10.067.

KINGMA, Diederik P.; LEI BA, Jimmy. ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION. [S. l.], 2014. Acesso em: 14 jun. 2023.

KRISHNA, Neeraj. **Backpropagation in RNN Explained**. 2022. Disponível em: <https://towardsdatascience.com/backpropagation-in-rnn-explained-bdf853b4e1c2>. Acesso em: 10 jun. 2023.

KRUSE, Rudolf; BORGELT, Christian; KLAWONN, Frank; MOEWES, Christian; STEINBRECHER, Matthias; HELD, Pascal. **Computational Intelligence: A Methodological Introduction**. 1. ed. Londres. v. 1 DOI: <https://doi.org/10.1007/978-1-4471-5013-8>. Disponível em: www.springer.com/series/3191. Acesso em: 15 abr. 2023.

KUSTER, Corentin; REZGUI, Yacine; MOURSHED, Monjur. Electrical load forecasting models: A critical systematic review. **Sustainable Cities and Society**, [S. l.], v. 35, p. 257–270, 2017. DOI: 10.1016/J.SCS.2017.08.009.

LEANDRO, Jhonatan Correa. **Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras**. 2021. Trabalho de Conclusão de Curso - Universidade federal da Grande Dourados, Dourados, 2021. Disponível em: <https://repositorio.ufgd.edu.br/jspui/bitstream/prefix/4806/1/JhonatanCorreaLeandro.pdf>. Acesso em: 4 maio. 2023.

LEE, Chang-Shing; MEMBER, Senior; WANG, Mei-Hui; NOJIMA, Yusuke; MAREK REFORMAT, Ieee; GUO, Leo. AI-Fuzzy Markup Language with Computational Intelligence for High-School Student Learning. **IEEE**, [S. l.], v. 1, p. 1–4, 2021. DOI: <https://doi.org/10.48550/arXiv.2112.01228>. Acesso em: 20 abr. 2023.

LEKSHMI, M.; ADITHYA SUBRAMANYA, K. N. Short-term load forecasting of 400kV grid substation using R-tool and study of influence of ambient temperature on the forecasted load. *Em: 2019 2ND INTERNATIONAL CONFERENCE ON ADVANCED COMPUTATIONAL AND COMMUNICATION PARADIGMS, ICACCP 2019 2019, Gangtok. Anais [...]*. Gangtok: IEEE, 2019. p. 1–5. DOI: 10.1109/ICACCP.2019.8883005.

LI, Chen. A fuzzy theory-based machine learning method for workdays and weekends short-term load forecasting. **Energy and Buildings**, Leiden, v. 245, p. 1–15, 2021. DOI: 10.1016/J.ENBUILD.2021.111072.

LUO, Hua; ZHANG, Haipeng; WANG, Jianzhou. Ensemble power load forecasting based on competitive-inhibition selection strategy and deep learning. **Sustainable Energy Technologies and Assessments**, China, v. 51, p. 1–13, 2022. DOI: 10.1016/J.SETA.2021.101940.

LV, Pin; LIU, Song; YU, Wenbing; ZHENG, Shuquan; LV, Jing. EGA-STLF: A Hybrid Short-Term Load Forecasting Model. **IEEE Power and Energy Society General Meeting**, Shanghai, v. 8, p. 31742–31752, 2020. DOI: 10.1109/ACCESS.2020.2973350. Disponível em: <https://ieeexplore.ieee.org/document/8995587>. Acesso em: 19 jan. 2022.

MAHANTA, Jahnvi. **Introduction to Neural Networks, Advantages and Applications**. 2017. Disponível em: <https://towardsdatascience.com/introduction-to-neural-networks-advantages-and-applications-96851bd1a207>. Acesso em: 23 abr. 2023.

MATSUMOTO, Daniel Kazuyuki Fugii. **Estudo em Séries Temporais Financeiras utilizando Redes Neurais Recorrentes**. 2019. Dissertação - Universidade Federal de Alagoas, Maceió, 2019. Disponível em: <https://www.repositorio.ufal.br/bitstream/riufal/6813/3/Estudo%20em%20s%c3%a9rie%20temporais%20financeiras%20utilizando%20redes%20neurais%20recorrentes.pdf>. Acesso em: 1 maio. 2023.

MATTMANN, Chris. **Machine Learning with TensorFlow**. 2. ed. [s.l.] : Manning Publications Co., 2021.

MCHUGH, Catherine; COLEMAN, Sonya; KERR, Dermot. Technical indicators for energy market trading. **Machine Learning with Applications**, [S. l.], v. 6, 2021. DOI: 10.1016/j.mlwa.2021.100182.

MILKE, Tafarel Franco. **METODOLOGIA PARA PREVISÃO DE CARGA NO HORIZONTE DE CURTO PRAZO UTILIZANDO REDES NEURAIIS**. 2019. Dissertação - Universidade federal de Santa Maria, Santa Maria, 2019. Disponível em: https://repositorio.ufsm.br/bitstream/handle/1/19743/DIS_PPGEI_2019_MILKE_TAFAREL.pdf?sequence=1&isAllowed=y. Acesso em: 23 abr. 2023.

MORETTIN, P. A.; TOLOI, C. M. **Análise de séries temporais**. 2. ed. São Paulo.

MULUALEM, Getachew Mehabie; LIOU, Yuei An. Application of Artificial Neural Networks in Forecasting a Standardized Precipitation Evapotranspiration Index for the Upper Blue Nile Basin. **Water** **2020**, Vol. **12**, Page **643**, [S. l.], v. 12, n. 3, p. 643, 2020. DOI: 10.3390/W12030643. Disponível em: <https://www.mdpi.com/2073-4441/12/3/643/htm>. Acesso em: 20 abr. 2023.

NELSON, David Michael Quirino. **USO DE REDES NEURAIIS RECORRENTES PARA PREVISÃO DE SÉRIES TEMPORAIS FINANCEIRAS**. 2017. Dissertação - Universidade Federal de Minas Gerais, Belo Horizonte, 2017. Acesso em: 1 maio. 2023.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **NT-096-2019: PREVISÃO DE CARGA PARA A PROGRAMAÇÃO DIÁRIA ELETROENERGÉTICA**. 2019. Disponível em: <http://www.ons.org.br/topo/acesso-restrito>. Acesso: 30 abr. 2023.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **ONS - Operador Nacional do Sistema Elétrico SINtegre**. 2023. Disponível em: <http://www.ons.org.br/topo/acesso-restrito>. Acesso em: 31 maio. 2023.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **O que é o SIN**. 2021a. Disponível em: <http://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>. Acesso em: 26 nov. 2021.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **2ª Revisão Quadrimestral das Projeções da demanda de energia elétrica**. Rio de Janeiro. Disponível em: [http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/NT 2ª Revisão Quadrimestral 2021-2025_VFF.pdf](http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/NT%202%C3%A1%20Revis%C3%A3o%20Quadrimestral%202021-2025_VFF.pdf). Acesso em: 26 nov. 2021b.

ONS. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **DADOS ABERTOS ONS**. 2021c. Disponível em: <https://dados.ons.org.br/>. Acesso em: 26 nov. 2021.

PANDIAN, Shanthababu. Time Series Analysis and Forecasting | Data-Driven Insights. **Analytics Vidhya**, [S. l.], 2023. Disponível em: <https://www.analyticsvidhya.com/blog/2021/10/a-comprehensive-guide-to-time-series-analysis/>. Acesso em: 8 jun. 2023.

PARK, D. C.; EL-SHARKAWI, M. A.; MARKS, R. J.; ATLAS, L. E.; DAMBORG, M. J. Electric load forecasting using an artificial neural network - Power Systems, IEEE

Transactions on. **IEEE Transadions on Power Systems**, [S. l.], v. 6, n. 2, p. 442–449, 1991.

PAULA, Flávio Alves De. **AS CAUSAS DA GRANDE RECESSÃO BRASILEIRA (2014 - 2016)**. 2019. Monografia - Universidade Federal de Uberlândia, Uberlândia, 2019. Disponível em:

<https://repositorio.ufu.br/bitstream/123456789/26518/3/CausasGrandeRecess%C3%A3o.pdf>. Acesso em: 10 jun. 2023.

PERE, Christophe. **What are Loss Functions?**. 2020. Disponível em:

<https://towardsdatascience.com/what-is-loss-function-1e2605aeb904>. Acesso em: 10 jun. 2023.

PIMENTA, RODRIGO GONÇALVES. **Modelo de previsão de carga de curtíssimo prazo aplicado na previsão do intercâmbio entre Itaipu e ANDE**. 2019.

Dissertação - UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ CAMPUS FOZ DO IGUAÇU, Foz do Iguaçu, 2019. Disponível em:

<http://tede.unioeste.br/handle/tede/4635>. Acesso em: 26 jan. 2022.

PINTAR, PEDRO HENRIQUE RAVAGNANI. **UM ESTUDO EXPLORATÓRIO SOBRE REDES NEURAIIS ARTIFICIAIS COM ÊNFASE NA REDE DE HOPFIELD**.

2018. Trabalho de Conclusão de Curso - Instituto Municipal de Ensino Superior de Assis, Assis, 2018. Acesso em: 13 maio. 2023.

PYTHON. **A Biblioteca Padrão do Python — documentação Python 3.11.4**. 2023.

Disponível em: <https://docs.python.org/pt-br/3/library/>. Acesso em: 9 jun. 2023.

QIUYU, Lu; QIUNA, Cai; SIJIE, Liu; YUN, Yang; BINJIE, Yan; YANG, Wang; XINSHENG, Zhou. Short-term Load Forecasting Based on Load Decomposition and Numerical Weather Forecast. *Em*: 2017 IEEE CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION (EI2) 2017, Beijing. **Anais [...]**. Beijing: IEEE, 2017. Disponível em: <https://ieeexplore.ieee.org/document/8245603>.

Acesso em: 19 jan. 2022.

R FOUNDATION. **R: The R Project for Statistical Computing**. 2023. Disponível em: <https://www.r-project.org/>. Acesso em: 7 jun. 2023.

RABELO, Leandro. **Princípios básicos para criar previsões de Séries Temporais**. 2019. Disponível em: <https://medium.com/ensina-ai/princ%C3%ADpios->

b%C3%A1sicos-para-criar-previs%C3%B5es-de-s%C3%A9ries-temporais-e58c451a25b. Acesso em: 20 maio. 2023.

RIBEIRO, Athyrson M.; ARAUJO JUNIOR, Francisco de Paula S. Um Estudo Comparativo Entre Cinco Métodos de Otimização Aplicados Em Uma RNC Voltada ao Diagnóstico do Glaucoma. **Revista de Sistemas e Computação**, Salvador, v. 10, p. 122–130, 2020. Disponível em: <http://www.revistas.unifacs.br/index.php/rsc>.

RIZZO, Igor Vilela; CANATO, Robson Leandro Carvalho. Inteligência artificial: funções de ativação. **Revista Prospectus**, [S. l.], p. 51–65, 2020.

ROCHA, Vinícius Rogério Da. **Modelo sequencial do Keras**. 2018. Disponível em: <https://www.monolitonimbus.com.br/modelo-sequencial-do-keras/>. Acesso em: 9 jun. 2023.

RUNGE, Jason; ZMEUREANU, Radu. Forecasting Energy Use in Buildings Using Artificial Neural Networks: A Review. **Energies** **2019**, Vol. **12**, Page **3254**, [S. l.], v. 12, n. 17, p. 3254, 2019. DOI: 10.3390/EN12173254. Disponível em: <https://www.mdpi.com/1996-1073/12/17/3254/htm>. Acesso em: 20 abr. 2023.

SANTANA, Thiago Balisa; SILVA, Benedito Cláudio Da; SANTOS, Afonso Henriques Moreira. ANÁLISE DE TENDÊNCIAS DE LONGO PRAZO EM SÉRIES DE VAZÕES: Estudo de caso na bacia do Alto Rio Grande (MG). **XIX Simpósio Brasileiro de Recursos Hídricos**, [S. l.], 2011.

SANTOS, DEILSON MARTINS DOS. **Otimização no atendimento à demanda de sistemas isolados considerando previsões de geração de energia elétrica por fontes renováveis**. 2021. Trabalho de Conclusão de Curso - Centro federal de educação tecnológica Celso Suckow da Fonseca - CEFET/RJ, Angra dos Reis, 2021.

SANTOS, Rosana Rodrigues Dos; FIGER, Vivian. **Transição energética: Brasil dribla a crise hídrica, mas permanece em alerta em relação a conta de luz**. 2022. Disponível em: <https://portal.fgv.br/artigos/transicao-energica-brasil-dribla-crise-hidrica-mas-permanece-alerta-relacao-conta-luz>. Acesso em: 10 jun. 2023.

SILVA, Juliana Mendes N. **Redes Neurais Artificiais: Rede Hopfield e Redes Estocásticas**. 2003. Dissertação - Universidade Federal Fluminense, Niterói, 2003. Acesso em: 13 maio. 2023.

SINGH, Saurabh; HUSSAIN, Shoeb; BAZAZ, Mohammad Abid. Short term load forecasting using artificial neural network. *Em: 2017 FOURTH INTERNATIONAL CONFERENCE ON IMAGE INFORMATION PROCESSING (ICIIP) 2017, Shimla. Anais [...]*. Shimla: IEEE, 2017. p. 1–5. DOI: 10.1109 / ICIIP.2017.8313703.

SOUSA, Alex Rodrigo dos Santos; SILVA, Cristiane da Silva; SILVA, Juliane Silveira Freire Da; OLIVEIRA, Rafaela Rodrigues. **Análise de séries temporais**. Porto Alegre: Grupo A, 2021. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9786556902876/>. Acesso em: 8 jun. 2023.

SOUZA, Carlos Eduardo. Séries temporais com Machine Learning — Parte. **Medium**, [S. l.], 2020. Disponível em: <https://medium.com/data-hackers/s%C3%A9ries-temporais-com-machine-learning-parte-1-e8fa62b82d48>. Acesso em: 8 jun. 2023.

SOUSA, Áurea. Coeficiente de Correlação de Pearson e Coeficiente de correlação de Spearman. O que medem e em que situações devem ser utilizados? **Correio dos Açores**. Açores. 21 mar. 2019. Disponível em: https://repositorio.uac.pt/bitstream/10400.3/5365/1/Sousa_CA_21%20Mar%c3%a7o%202019.pdf. Acesso em: 04 jul. 2023.

SUGANDHI, Abhresh. What is Long Short Term Memory (LSTM). **knowledgehut up Grad**, [S. l.], 2023. Disponível em: <https://www.knowledgehut.com/blog/web-development/long-short-term-memory>. Acesso em: 10 jun. 2023.

TANG, Xianlun; CHEN, Hongxu; XIANG, Wenhao; YANG, Jingming; ZOU, Mi. Short-Term Load Forecasting Using Channel and Temporal Attention Based Temporal Convolutional Network. **Electric Power Systems Research**, Chongqing, v. 205, p. 1–13, 2022. DOI: 10.1016/J.EPSR.2021.107761.

VIEIRA, Elias Queiroga. **Comparação entre diferentes modelos de redes neurais convolucionais para classificação de melanoma**. 2022. Trabalho de conclusão de curso - Universidade de Brasília, Brasília, 2022. Acesso em: 14 jun. 2023.

WILLINGHAM, David. **Electricity Load Forecasting for the Australian Market Case Study**. 2012. Disponível em:

<https://nl.mathworks.com/matlabcentral/fileexchange/31877-electricity-load-forecasting-for-the-australian-market-case-study>. Acesso em: 4 fev. 2022.

WU, Fei; CATTANI, Carlo; SONG, Wanqing; ZIO, Enrico. Fractional ARIMA with an improved cuckoo search optimization for the efficient Short-term power load forecasting. **Alexandria Engineering Journal**, [S. l.], v. 59, n. 5, p. 3111–3118, 2020. DOI: 10.1016/J.AEJ.2020.06.049.

XAVIER, THAINÁ SANTOS. **PREVISÃO DE SÉRIES TEMPORAIS UTILIZANDO MODELOS CLÁSSICOS E REDES NEURAIS ARTIFICIAIS**. 2018. Trabalho de Conclusão de Curso (Curso Superior bacharel Ciência no domínio da Engenharia Elétrica) - Departamento acadêmico de Engenharia Elétrica, UFCG, Campina Grande, 2018. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/18949>. Acesso em: 27 jan. 2022.

ZHANG, Jinliang; WEI, Yi Ming; LI, Dezhi; TAN, Zhongfu; ZHOU, Jianhua. Short term electricity load forecasting using a hybrid model. **Energy**, Beijing, v. 158, p. 774–781, 2018. DOI: 10.1016/J.ENERGY.2018.06.012.

ZHOU, Ke; ZHOU, Yusheng; DENG, Kangjian. A Circular Recursion Algorithm Power Load Forecasting Model and Application. **Anais [...]**. Changsha: IEEE, 2019. p. 2870–2873. DOI: 10.1109/EI247390.2019.9061824.

ZOU, Zhiyong; WU, Xiangwei; ZHAO, Zhengyang; WANG, Qi; BIE, YunBo; ZHOU, Man. Prediction of Short Term Electric Load Based on BP Neural Networks & ARIMA Combination. **IEEE**. Sichuan Province, p. 1671–1674, 2018. DOI: 10.1109 / ITOEC.2018.8740553.

Anexo 1

Anexo A – Código

O código apresentado a seguir, foi utilizado para realização da análise e manipulação do conjunto dados; e para realização das previsões de carga a curto prazo.

1. Análise e manipulação de dados

Importação das bibliotecas e do conjunto de dados

```
#para manipular arquivos
import pandas as pd
from numpy import NaN
import numpy as np

from glob import glob #ler varios arquivos de uma pasta

#para plotar graficos
import sys
import matplotlib.pyplot as plt

%matplotlib inline
import seaborn as sns
import os

[ ] #importando dados dos arquivos excell
Data_base = pd.read_excel('/content/drive/MyDrive/Dados Sul - Temperatura vs Carga/Dados de carga e temperatura subsistema sul (1).xlsx')

[ ] # Obtendo estatísticas descritivas do conjunto de dados Data_base
Data_base.describe()
```

Identificação da presença de dados ausentes, nulos ou inconsistentes nos conjuntos de dados de carga e temperatura

```
[ ] # Verificar valores nulos na coluna "carga"
valores_nulos = Data_base['Carga'].isnull().sum()

# Verificar valores negativos na coluna "carga"
valores_negativos = (Data_base['Carga'] < 0).sum()

# Exibir os resultados
print("Valores nulos na coluna 'Carga':", valores_nulos)
print("Valores negativos na coluna 'Carga':", valores_negativos)

[ ] # Identificar linhas com valores negativos na coluna "carga"
linhas_valores_negativos = Data_base[Data_base['Carga'] < 0]

# Exibir as linhas com valores negativos
if not linhas_valores_negativos.empty:
    print("Valores negativos encontrados nas seguintes linhas:")
    print(linhas_valores_negativos)
else:
    print("Não foram encontrados valores negativos na coluna 'carga'.")

[ ] # Verificar valores nulos na coluna "Temperatura"
valores_nulos = Data_base['Temperatura'].isnull().sum()

# Verificar valores negativos na coluna "Temperatura"
valores_negativos = (Data_base['Temperatura'] < 0).sum()

print("Valores nulos na coluna 'Temperatura':", valores_nulos)
print("Valores negativos na coluna 'Temperatura':", valores_negativos)

[ ] # Filtrando as linhas com valores de temperatura menores ou iguais a zero
filtered_rows = Data_base[Data_base['Temperatura'] <= 0]

# Verificando se há linhas filtradas
if not filtered_rows.empty:
    # Imprimindo as linhas filtradas
    print(filtered_rows)
else:
    # Caso não haja linhas filtradas, imprime uma mensagem de aviso
    print("Não foram encontradas linhas com valores iguais ou menores que zero na coluna 'Temperatura'.")
```

```
[ ] rows_with_null_values = Data_base[Data_base['Temperatura'].isnull()]

# Imprimir as linhas com valores nulos na coluna de temperatura
print("linhas com valores nulos de temperatura:")
print(rows_with_null_values)
```

Plotagem de gráficos para examinar os padrões e comportamentos dos conjuntos de dados ao longo dos anos

```
[ ] #Selecionando as colunas do dataset
Data_base = Data_base[['Carga', 'Temperatura', 'Data']]
```

```
[ ] # Converte a coluna de datas para o formato de data
Data_base['Data'] = pd.to_datetime(Data_base['Data'])

# Define a coluna de datas como o índice dos dados
Data_base.set_index('Data', inplace=True)
```

```
▶ #Gráfico variação média da carga mensal e da temperatura mensal ao longo dos anos
fig, (ax1, ax2) = plt.subplots(2, 1, figsize=(8, 6))

Data_base.Carga.resample('m').mean().plot(ax=ax1)
ax1.set_xlabel('Ano')
ax1.set_ylabel('Carga média')
ax1.set_title('Variação Média da Carga Mensal ao Longo do Tempo')
ax1.grid(True)
ax1.legend(loc='upper right')

Data_base.Temperatura.resample('m').mean().plot(ax=ax2)
ax2.set_xlabel('Ano')
ax2.set_ylabel('Temperatura média')
ax2.set_title('Variação Média da Temperatura Mensal ao Longo do Tempo')
ax2.grid(True)
ax2.legend(loc='upper right')

plt.tight_layout()
plt.show()
```

```
[ ] # Cria a figura e os subplots
fig, (ax1, ax2) = plt.subplots(2, 1, figsize=(10, 12))

# Plota o gráfico da série temporal da Carga
ax1.plot(Data_base.index, Data_base['Carga'], color='blue', label='Carga')
ax1.set_xlabel('Ano')
ax1.set_ylabel('Carga')
ax1.set_title('Série Temporal da Carga e Temperatura ao Longo dos Anos')
ax1.grid(True)
ax1.legend(loc='upper right')

# Plota o gráfico da série temporal da Temperatura
ax2.plot(Data_base.index, Data_base['Temperatura'], color='green', label='Temperatura')
ax2.set_xlabel('Ano')
ax2.set_ylabel('Temperatura')
ax2.grid(True)
ax2.legend(loc='upper right')

# Ajusta o espaçamento entre os subplots
fig.tight_layout()

# Exibe a figura
plt.show()
```

Correlação entre os conjuntos de dados

```
▶ from scipy.stats import spearmanr
from scipy.stats import pearsonr

# Extrair as colunas de carga e temperatura
Carga_cor = Data_base['Carga']
Temperatura_cor = Data_base['Temperatura']

# Calcular a correlação de Spearman
correlation, p_value = spearmanr(Carga_cor, Temperatura_cor)

# Calcular a correlação de Pearson
correlation_2, p_value_2 = pearsonr(Carga_cor, Temperatura_cor)

# Imprime o resultado
print("Correlação de Spearman:", correlation)
print("Valor de p:", p_value)

print("Correlação de Pearson:", correlation_2)
print("Valor-p:", p_value_2)
```



```

# Cria as colunas deslocadas no tempo para as saídas futuras
for i in range(0, n_saida):
    colunas.append(prepared_data_set.shift(-i))
    if i == 0:
        # Atualiza os nomes das colunas com rótulos indicando o tempo atual (t)
        nomes += [('var%d(t)' % (j + 1)) for j in range(n_vars)]
    else:
        # Atualiza os nomes das colunas com rótulos indicando o tempo futuro (t+1, t+2, ...)
        nomes += [('var%d(t+%d)' % (j + 1, i)) for j in range(n_vars)]

# Concatena as colunas e gera um novo DataFrame com os dados transformados
prepared_data_set = pd.concat(colunas, axis=1)
# Atribui os nomes atualizados às colunas do DataFrame
prepared_data_set.columns = nomes

# Remove as linhas com valores ausentes, se necessário
if dropnan:
    prepared_data_set.dropna(inplace=True)

# Retorna o conjunto de dados transformado
return prepared_data_set

```

Preparação dos dados

```

[6] def prepare_to_lstm(data_set):
    # Remove as colunas "Data" e "date" do conjunto de dados
    values = data_set.drop(columns=["Data", "date"]).values.astype(np.float32)

    # Aplica a normalização dos valores no intervalo de 0 a 1 usando MinMaxScaler
    normal = MinMaxScaler(feature_range=(0, 1))
    prepared_data_set = pd.DataFrame(normal.fit_transform(values))

    # Aplica a transformação para o formato adequado para uma rede LSTM usando a função transform_to_lstm
    prepared_data_set = transform_to_lstm(prepared_data_set, 1, 1)

    # Retorna o conjunto de dados preparado e o objeto normalizador
    return prepared_data_set, normal

```

Preparação dos dados para treinamento e teste

```

def preparation_data(df):
    # Divisão dos dados em treinamento e validação
    train, test = train_test_split(df, test_size=TEST_SIZE, shuffle=False)

    # Preparação dos dados de treinamento e validação
    train_x = train.drop(columns=["var1(t)", "var2(t)", "var3(t)", "var4(t)", "var5(t)", "var6(t)"]).values.astype(np.float32)
    train_y = train["var1(t)"].values.astype(np.float32)
    test_x = test.drop(columns=["var1(t)", "var2(t)", "var3(t)", "var4(t)", "var5(t)", "var6(t)"]).values.astype(np.float32)
    test_y = test["var1(t)"].values.astype(np.float32)

    # Reformular os dados de entrada para adicionar a dimensão temporal
    train_x = np.reshape(train_x, (train_x.shape[0], train_x.shape[1], 1))
    test_x = np.reshape(test_x, (test_x.shape[0], test_x.shape[1], 1))

    return train_x, train_y, test_x, test_y

```

```

def train_model(train_x, train_y, test_x, test_y):
    # Definindo a forma de entrada para o modelo
    input_shape = (train_x.shape[1], train_x.shape[2])

    # Criando o modelo da rede neural LSTM
    model = tf.keras.models.Sequential([
        tf.keras.layers.LSTM(HIDDEN_1_NEURONS, activation=HIDDEN_1_ACTIVATION, input_shape=input_shape),
        tf.keras.layers.Dense(HIDDEN_2_NEURONS, activation=HIDDEN_2_ACTIVATION),
        tf.keras.layers.Dense(OUTPUT_NEURONS)
    ])

    # Compilando o modelo com a função de perda e otimizador
    model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=LEARNING_RATE), loss=LOSS)

    # Treinando o modelo
    history = model.fit(train_x, train_y, batch_size=BATCH_SIZE, epochs=EPOCHS, validation_data=(test_x, test_y))

    return model, history

```

Definição da função que irá realizar a predição

```
def predict(model, test_x, test_y, normal):
    # Realiza a previsão com base no modelo fornecido
    prev = model.predict(test_x)

    # Redimensiona o conjunto de teste para o formato original
    reshape = (test_x.shape[0], test_x.shape[1])
    test_x = test_x.reshape(reshape)

    # Combina as previsões com os dados de entrada
    predictions = np.concatenate((prev, test_x[:, 1:]), axis=1)

    # Inverte a normalização das previsões
    predictions = normal.inverse_transform(predictions)
    predictions = predictions[:, 0]

    # Redimensiona os dados de teste para o formato original
    test_y = test_y.reshape((len(test_y), 1))

    # Combina os dados de teste com os dados de entrada
    labels = np.concatenate((test_y, test_x[:, 1:]), axis=1)
```

```
# Inverte a normalização dos rótulos
labels = normal.inverse_transform(labels)
labels = labels[:, 0]

# Retorna as previsões e os rótulos
return predictions, labels
```

Função de perda

```
[10] def evaluate_model_test(model, history, test_x, test_y, predictions):
    # Plotagem dos resultados
    plt.plot(history.history['loss'], label='Training Loss') # Plot da função de perda durante o treinamento
    plt.plot(history.history['val_loss'], label='Validation Loss') # Plot da função de perda durante a validação
    plt.xlabel('Epoch') # Rótulo do eixo x indicando as épocas
    plt.ylabel('Loss') # Rótulo do eixo y indicando a perda
    plt.legend() # Exibe a legenda no gráfico
    plt.show() # Mostra o gráfico
```

Função principal que executa várias etapas para realização da previsão de carga

```
def main():

    df = dataset()

    prepared_data_set, normal = prepare_to_lstm( df )

    train_x, train_y, test_x, test_y = preparation_data(prepared_data_set)

    # Treinamento do modelo
    model, history = train_model(train_x, train_y, test_x, test_y)

    # Realizar previsões com o modelo treinado
    predictions, labels = predict( model, test_x, test_y, normal )

    # Avaliação do modelo
    evaluate_model_test(model, history, test_x, test_y, predictions)

    mse = mean_squared_error(labels, predictions)
    mae = mean_absolute_error(labels, predictions)
    r2 = r2_score(labels, predictions)
    mape = mean_absolute_percentage_error(labels, predictions)

    metrics = pd.DataFrame(data={'mse': [mse], 'mae': [mae], 'r2': [r2], 'mape': [mape]})
    print(metrics)

    # Encontrar posição da data nos dados de teste para gerar os graficos
    test_dates = df["date"].iloc[-len(test_x):].dt.date.tolist()
    date_to_find = pd.to_datetime("2020-11-25").date()
    date_index = test_dates.index(date_to_find)

    idx = date_index

    plt.figure(figsize=(12, 6))
    plt.plot(labels[idx:idx+24], label='Medição')
    plt.plot(predictions[idx:idx+24], linestyle='dotted', label='Previsão')
    plt.xlabel('Horas')
    plt.ylabel('Carga (MW)')
    mape_1 = mean_absolute_percentage_error(labels[idx:idx+24], predictions[idx:idx+24])
    plt.legend()
    plt.xlim(0, 23)

    plt.title('Erro MAPE: {:.4f}'.format(float(mape_1)), loc='right')
    plt.show()
    print(mape_1)
```


```
# Plotar gráfico da carga prevista e carga real para o último mês
plt.figure(figsize=(12, 6))
plt.plot(labels[:30*24], label='Carga Real')
plt.plot(predictions[:30*24], label='Carga Prevista')
plt.xlabel('Data')
plt.ylabel('Carga')
plt.title('Carga Real vs. Carga Prevista (Último mês)')
plt.legend(mape_1)
plt.xticks(rotation=45)
plt.show()
```

```
[13] if __name__ == '__main__':
      main()
```

Anexo B – Dados de entrada

Os conjuntos de dados referem-se aos decks de entrada usados pelo modelo ONS de previsão de carga, chamado prevCargaDessem. Esses conjuntos de dados são fornecidos pelo Operador Nacional do Sistema Elétrico (ONS) por meio do portal SINtegre, e são atualizados diariamente. Para ter acesso aos dados o usuário deve fazer o seu cadastro pessoal (Ver Figura 30). Na página inicial, na opção “busca” busque por “Arquivos de previsão de carga”.

Figura 30 - Portal SINtegre ONS



Fonte: ONS (2023).