

Aplicação de redes neurais para previsão de demanda de energia elétrica

Douglas dos Santos Café ^a e Celso Ap.de França ^b

Departamento de Engenharia Elétrica da Universidade Federal de São Carlos

Resumo – No início dos anos 2000, o sistema elétrico brasileiro encontrava-se menos desenvolvido que atualmente e dependia muito mais da geração hidroelétrica, pois 80% provinha da mesma. Um estudo conduzido pelo Ministério de Minas e Energia revelou que a possibilidade de déficit de eletricidade no final da década de 90 estava em patamares acima do aceitável e o equilíbrio entre oferta e demanda era precário.

Por isso, foi criado o programa de racionalização do uso de energia elétrica, dividido em dois estágios. O primeiro era a racionalização, e caso não fosse reduzido o risco de demanda maior que a oferta, o governo acionaria o segundo estágio, o racionamento. Sendo assim, para que ocorra um melhor planejamento e uma produção mais eficiente, evitando uma produção excessiva ou abaixo da demanda, torna-se indispensável utilizar e aprimorar metodologias de previsão de demanda de energia elétrica.

Posto isto, o atual trabalho visa o desenvolvimento de uma ferramenta computacional de apoio para o planejamento estratégico em sistemas de geração e distribuição elétrica. Na metodologia proposta será implementado um sistema de previsão a curto/médio prazo para o estado de São Paulo, utilizando de técnicas computacionais de inteligência artificial fundamentadas em redes neurais artificiais (RNA). Para tal, foi utilizado dados de consumo de energia elétrica na rede (MWh), adquiridos através dos portais eletrônicos da Agência Nacional de Energia Elétrica (ANEEL) e Empresa de Pesquisa Energética (EPE).

Palavras-Chave – Previsão de Demanda, Geração de Energia Elétrica, Distribuição de Energia Elétrica, Inteligência Artificial, Redes Neurais Artificiais.

1. INTRODUÇÃO

A previsão de demanda energética é um fator crítico para garantir o fornecimento adequado de energia elétrica em uma região. No Estado de São Paulo, a previsão de demanda é especialmente desafiadora devido a grande população e a alta densidade industrial da região. Nesse contexto, a utilização de técnicas avançadas de previsão, como as redes neurais artificiais (RNAs), pode oferecer melhorias significativas na precisão e eficácia da previsão de demanda.

RNAs representam um tipo de modelo de aprendizado de máquina capaz de aprender a prever padrões com base em dados históricos.

As RNAs podem aprender com os dados de demanda de energia elétrica do passado, bem como com outras variáveis relevantes, como o clima, a atividade econômica e o comportamento do consumidor, para gerar previsões precisas da demanda futura.

A previsão de demanda energética com uso de RNAs pode ajudar as empresas de energia elétrica a planejar de forma mais eficiente seus investimentos em geração e distribuição de energia, aprimorando a confiabilidade do sistema e reduzindo o risco de interrupções no fornecimento de energia elétrica.

No entanto, é importante lembrar que a previsão de demanda energética não é uma tarefa fácil e requer conhecimento especializado e habilidades analíticas avançadas. Além disso, é importante garantir que as RNAs sejam treinadas com dados relevantes e de alta qualidade, para que as previsões geradas sejam confiáveis e precisas.

Nesse contexto, a previsão de demanda energética com uso de RNAs pode trazer importantes benefícios para o Estado de São Paulo, ajudando a garantir um fornecimento seguro e estável de energia elétrica para a população e as empresas da região.

Portanto, o objetivo deste trabalho é apresentar uma abordagem baseada em RNAs para a previsão de demanda energética no Estado de São Paulo. Especificamente, o trabalho visa avaliar a capacidade das RNAs em prever com precisão a demanda futura de energia elétrica no Estado.

2. TRABALHOS RELACIONADOS

A previsão de demanda energética tem se mostrado uma tarefa desafiadora, porém extremamente importante para o planejamento e operação do sistema elétrico. Nos últimos anos, as redes neurais artificiais têm sido cada vez mais utilizadas para prever a demanda energética, pois podem lidar com a complexidade e incertezas inerentes ao processo de previsão.

Um estudo realizado por Zhang et al. [1] aplicou redes neurais artificiais na previsão de demanda de energia elétrica em um sistema de cogeração. Os resultados mostraram que o modelo de rede neural artificial foi capaz de prever com 96,1% de precisão a demanda de energia elétrica em diferentes horários do dia.

Em outro estudo, realizado por Wang et al. [2], as redes neurais artificiais foram aplicadas na previsão de demanda de energia elétrica em uma cidade chinesa. Os resultados mostraram que a precisão da previsão melhorou significativamente com o uso de redes neurais artificiais, em comparação com outros métodos de previsão.

Um estudo realizado por Ramírez-Rosado et al. [3] utilizou redes neurais artificiais na previsão da demanda de eletricidade em um sistema de energia renovável. Os resultados mostraram que o modelo proposto foi capaz de prever com 98,2% de precisão a demanda de eletricidade, levando em consideração as condições meteorológicas e a disponibilidade de energia renovável.

Outro estudo, realizado por Cholakova et al. [4], aplicou redes neurais artificiais na previsão da demanda de eletricidade em um sistema de distribuição de energia. Os resultados mostraram que o modelo proposto foi capaz de prever com 97,4% a demanda de eletricidade em diferentes horários do dia,

^a E-mail autor: douglassantoscfe@estudante.ufscar.br

^b E-mail orientador: celsofr@ufscar.br

levando em consideração fatores como a temperatura e a umidade.

Finalmente, um estudo realizado por Kim et al. [5] aplicou redes neurais artificiais na previsão da demanda de energia elétrica em uma empresa de manufatura. Os resultados mostraram que o modelo proposto foi capaz de prever com 96,2% precisão a demanda de energia elétrica, levando em consideração os dados históricos de consumo de energia elétrica e as informações meteorológicas.

Esses estudos demonstram que as redes neurais artificiais têm se mostrado uma ferramenta eficiente para a previsão de demanda energética, em diferentes contextos e com diferentes variáveis de entrada. Isso destaca a importância do uso de técnicas avançadas de previsão, como as redes neurais artificiais, para aprimorar o planejamento e a operação do sistema elétrico.

3. FUNDAMENTAÇÃO TEÓRICA

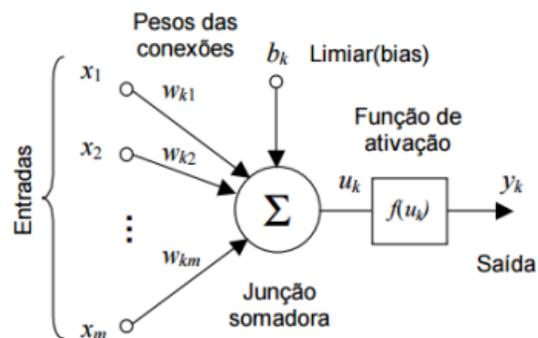
As redes neurais artificiais (RNAs) são modelos matemáticos que permitem aprendizado através de processamento computacional, tendo como base as redes de neurônios biológicos [6]. O processamento das informações nas RNAs ocorre por meio de estruturas de armazenamento e processamento, em que cada unidade de processamento é um neurônio. O neurônio genérico em RNA, recebe entradas ponderadas por pesos e produz uma saída por meio da aplicação de uma função de ativação.

Em séries temporais, uma técnica utilizada para determinar as entradas do modelo de previsão baseado em RNAs é a extração dos componentes de tendência e ciclo dos próprios dados da série [7]. A previsão é feita usando os componentes cíclicos e a tendência é extrapolada para obter o resultado final. A precisão do modelo é avaliada comparando os resultados com os dados históricos de demanda, e a previsão é considerada satisfatória quando se aproxima dos dados reais. Isso demonstra que as RNAs são uma opção viável para a previsão de séries temporais, graças à sua capacidade de aprendizado por generalização usando os registros históricos.

3.1 Neurônio artificial - Perceptron

A rede neural Perceptron é conhecida por ter entrada intervalar, utilizar aprendizado supervisionado e alimentação à frente. Sua operação envolve um combinador adaptativo linear, em que a saída é obtida pela combinação linear das entradas, resultando em um vetor que é multiplicado por pesos [8].

Figura 1 - O Neurônio Genérico em RNAs (Perceptron)



Fonte: Castro e Zuben, 2015 [7]

onde a figura 1, o x_i representa as entradas, o b representa a bias para controlar o neurônio e o w_i são os pesos.

Dentre os modelos de Redes Neurais Artificiais (RNAs), podemos destacar o *Multilayer Perceptron* (MLP), as Redes de Função de Base Radial (RBF) e as Redes de Função Sample (SFNN) [9]. A escolha do modelo mais adequado pode ser uma tarefa complexa, dada a diversidade de opções disponíveis. Embora nem todos os modelos possam oferecer uma solução ótima, uma vantagem do uso das redes MLP é seu rápido processo de treinamento.

3.2 Perceptron de múltiplas camadas

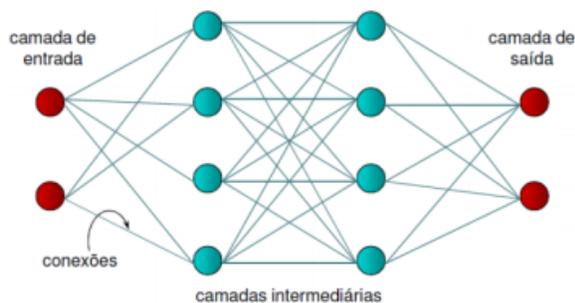
A arquitetura utilizada para modelar o presente trabalho envolve o uso de redes em camadas, que são compostas por uma camada de entrada e uma ou mais camadas ocultas, seguidas por uma camada de saída. O sinal é transmitido de maneira direcional dentro da rede, passando por cada camada até chegar à saída.

Segundo Vellasco [10], as redes em camadas apresentam três características básicas:

1. Cada neurônio da rede possui um modelo que inclui uma função de ativação não linear, sendo a não linearidade sigmóide uma das formas utilizadas.
2. Essas redes possuem uma ou mais camadas de neurônios ocultos que não fazem parte da saída da rede.
3. A conectividade da rede é altamente determinada por seus pesos, sendo que alterações na conectividade exigem modificações nesses pesos.

Devido às limitações do perceptron de camada simples, que possuía fronteiras de decisão lineares e funções de lógica simplificadas, foi criado o Multilayer Perceptron (MLP), ilustrado na Figura 2. Essa arquitetura é composta por uma camada de entrada, uma ou mais camadas intermediárias (também conhecidas como camadas ocultas) e uma camada de saída.

Figura 2 - Representação de uma MLP

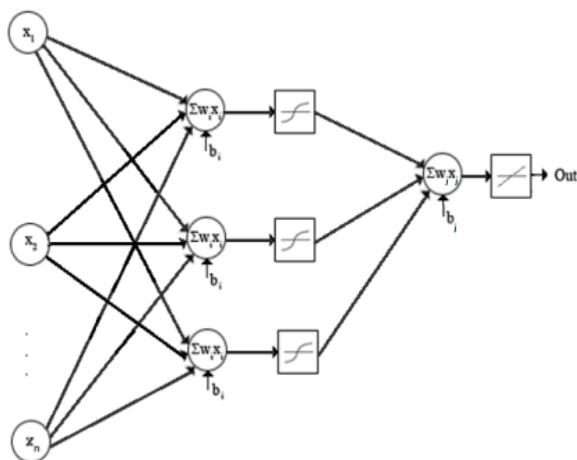


Fonte: Soares e Silva, 2011 [9]

No *Multilayer Perceptron* (MLP), o processamento da informação ocorre em duas fases distintas. Na fase de propagação, o sinal de entrada é transmitido pela rede, camada por camada, até gerar uma saída. Já na fase de adaptação, os pesos da rede são ajustados.

A arquitetura do MLP com apenas uma saída é ilustrada na Figura 3. Nessa arquitetura, a camada intermediária utiliza uma função sigmóide como função de ativação, enquanto a camada de saída emprega uma função de ativação linear.

Figura 3 - Arquitetura da MLP para única saída



Fonte: Soares e Silva, 2011 [9]

As MLPs são utilizadas para resolver problemas através do treinamento supervisionado, em que a rede recebe uma resposta que é comparada com a saída desejada, permitindo que seja informada sobre o erro da resposta atual. Para minimizar os erros quadráticos, existem algoritmos capazes de fazer o treinamento.

A técnica conhecida como *Backpropagation*, que consiste no aprendizado por correção do erro da camada de saída e retropropagação para as camadas intermediárias da RNA, pode ser usada para solucionar o problema. Em relação a cada camada, a camada de saída recebe os estímulos da camada intermediária e gera o padrão de resposta, enquanto as camadas intermediárias funcionam como extratoras de características.

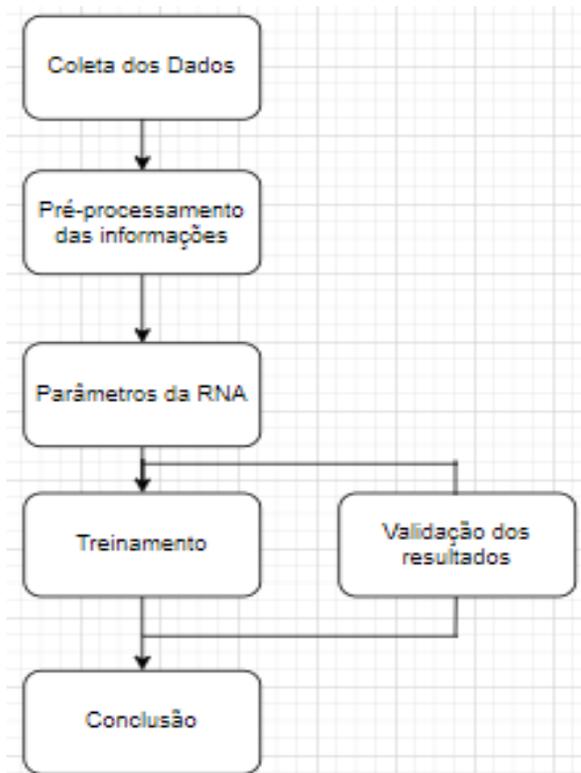
Os pesos das camadas intermediárias seguem a codificação

de características e são apresentados nos padrões de entrada, permitindo que a rede crie sua própria representação. [10]

4. METODOLOGIA

O modelo apresentado neste trabalho foi desenvolvido seguindo o fluxograma apresentado na Figura 4. Esse fluxograma descreve todas as etapas desde a coleta e processamento dos dados, finalizando na interpretação dos resultados finais.

Figura 4 - Fluxograma do projeto



Fonte: Autor

A etapa de coleta de dados é uma das mais importantes no processo de análise de dados, uma vez que a qualidade e a precisão dos dados coletados influenciam diretamente nos resultados finais da análise. A coleta de dados consiste na obtenção de informações relevantes a partir de diversas fontes. Posto isto, foram coletados dados de 2010 a 2020 em fontes oficiais e confiáveis, como órgãos reguladores do setor elétrico e empresas de distribuição de energia. As principais fontes de dados foram:

- Agência Nacional de Energia Elétrica (ANEEL)
- Empresa de Pesquisa Energética (EPE)
- Câmara de Comercialização de Energia Elétrica (CCEE)

A Tabela 2 apresenta uma amostra dos dados extraídos do site oficial da Câmara de Comercialização de Energia Elétrica com as informações de consumo de energia elétrica em 2022 no Estado de São Paulo.

Tabela 1 - Dados de consumo disponível no CCEE

UF	data	Data_Mensal	Última Data	Ano Anterior	Ano atual	Consumo (MWh)	Consumo (MWh)	Consumo (MWh)_old
SP	1/4/22	1/4/21	17/3/23	17154		501,73	20,905	20,905
SP	1/4/22	1/4/21	17/3/23	17154		258781	10783	10783
SP	1/4/22	1/4/21	17/3/23	17154		15,529	0,6471	0,6471
SP	1/4/22	1/4/21	17/3/23	17154		3932,8	163,87	163,87
SP	1/4/22	1/4/21	17/3/23	17154		1,4526	0,0605	0,0605
SP	1/4/22	1/4/21	17/3/23	17154		229,32	9,5552	9,5552
SP	1/4/22	1/4/21	17/3/23	17154		9068,6	377,86	377,86
SP	1/4/22	1/4/21	17/3/23	17154		63,849	2,6604	2,6604
SP	1/4/22	1/4/21	17/3/23	17154		1299,6	54,151	54,151
SP	1/4/22	1/4/21	17/3/23	17154		12,464	0,5193	0,5193
SP	1/4/22	1/4/21	17/3/23	17154		7499,5	312,48	312,48
SP	1/4/22	1/4/21	17/3/23	17154		41,176	1,7157	1,7157
SP	1/4/22	1/4/21	17/3/23	17154		1282,8	53,452	53,452
SP	1/4/22	1/4/21	17/3/23	17154		202,49	8,4372	8,4372
SP	1/4/22	1/4/21	17/3/23	17154		17,134	0,7139	0,7139
SP	1/4/22	1/4/21	17/3/23	17154		42,71	1,7796	1,7796
SP	1/4/22	1/4/21	17/3/23	17154		431,7	17,988	17,988
SP	1/4/22	1/4/21	17/3/23	17154		5214,2	217,26	217,26
SP	1/4/22	1/4/21	17/3/23	17154		10921	455,05	455,05

Fonte: Adaptado do CCEE [11]

Após o processo de coleta de dados, inicia-se o processo de pré-processamento que consiste em um conjunto de atividades que visam preparar, organizar e estruturar os dados antes da realização de análises e previsões. É uma etapa essencial que influencia significativamente a qualidade dos dados finais e pode impactar diretamente o modelo de previsão gerado a partir desses dados.

Existem vários problemas comuns que podem ser encontrados em conjuntos de dados, incluindo atributos com valores faltantes, *outliers* e escalas diferentes para valores iguais. É importante identificar e resolver esses problemas durante o processo de pré-processamento para garantir a confiabilidade e a precisão das análises e previsões realizadas posteriormente. Um código em Python foi desenvolvido para realizar a limpeza e preparação dos dados, a fim de que pudessem ser utilizados como entrada no modelo de predição.

O código desenvolvido para limpeza e preparação de dados envolveu várias etapas, incluindo identificar e tratar dados ausentes, duplicados, inconsistentes ou incorretos, padronizar e verificar a consistência e validade dos dados, como por exemplo, consumo de energia elétrica negativo.

A fase de parametrização das redes neurais artificiais é uma etapa crucial no processo de treinamento e construção dessas redes. Durante essa fase, o objetivo é ajustar os parâmetros da rede neural para que ela possa aprender a mapear as entradas para as saídas desejadas com precisão e eficiência.

Os principais parâmetros que precisam ser ajustados durante a parametrização são: Arquitetura, algoritmo de treinamento, número de camadas e neurônios, função de ativação, taxa de aprendizagem e função de custo. Sendo assim, as redes neurais foram parametrizadas conforme a Tabela 2.

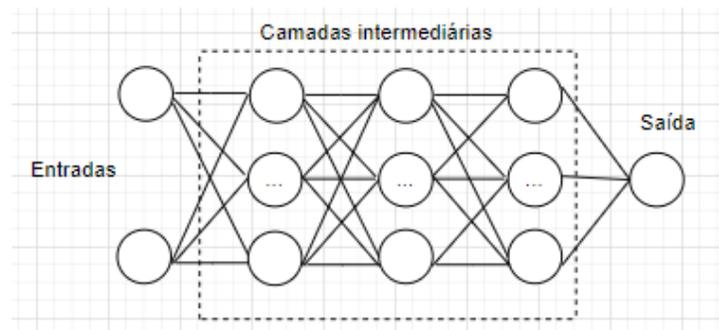
Tabela 2 - Parâmetros

Arquitetura	Multilayer Perceptron
Algoritmo de treinamento	Backpropagation
Número de camadas	3
Quantidade de épocas	500
Neurônios de camadas intermediária	Função de ativação sigmóide
Neurônios da camada de saída	Função de ativação linear

Fonte: Autor

Com isso, foi definida a arquitetura utilizada no projeto, como mostra a Figura 5. Inicialmente, para cada camada intermediária foram alocados 5 neurônios. Ao longo do projeto, foi necessário fazer o acréscimo de novos neurônios, mudando a distribuição nas camadas intermediárias.

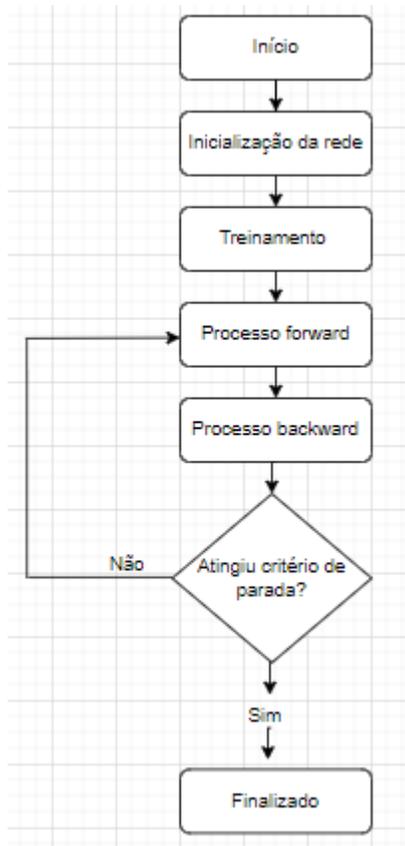
Figura 5 - Arquitetura do modelo



Fonte: Autor

Depois de ajustar os parâmetros da rede neural, é necessário treiná-la usando um conjunto de dados de treinamento e um algoritmo de aprendizagem apropriado. A rede neural é treinada repetidamente até que ela possa produzir saídas precisas e consistentes para as entradas fornecidas. A Figura 6, mostra o fluxograma do processo de treinamento da RNA, porém todo o processo foi escrito na linguagem Python.

Figura 6 - Fluxograma treinamento RNA



Fonte: Autor

Para avaliar o desempenho das RNAs, foram utilizados dois indicadores de desempenho:

- Erro Absoluto Médio (Mean Absolute Error - MAE)
- Erro Absoluto Percentual Médio (Mean Absolute Percentual Error - MAPE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad (1)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|x_i - x|}{x_i} \quad (2)$$

onde, x_i representa o valor desejado e x o valor estimado pela RNA e n é o número de amostras usadas para validação.

5. RESULTADOS E DISCUSSÕES

Inicialmente, a seleção dos dados de entrada para a RNA foi feita com base na autocorrelação da série. Para obter um valor de entrada diversificado, considerou os atrasos correlacionados dentro de um intervalo de confiança de 95%.

A fórmula para a autocorrelação de pode ser expressa da seguinte maneira:

$$r(k) = \frac{\sum (x_i - x) * (x_{i-k} - x)}{(n-1)s^2} \quad (3)$$

onde:

- $r(k)$ é a autocorrelação no deslocamento k ;
- x_i é o valor da série temporal no momento i ;
- x é a média dos valores da série temporal;
- x_{i-k} é o valor da série temporal no momento $i-k$;
- n é o número de observações na série temporal;
- s^2 é a variância dos valores da série temporal.

Essa fórmula pode ser utilizada para calcular a autocorrelação para diferentes valores de k , onde k é o número de períodos de tempo entre os valores sendo comparados. A autocorrelação pode variar de -1 a 1, onde -1 indica uma correlação negativa perfeita, 0 indica ausência de correlação e 1 indica uma correlação positiva perfeita.

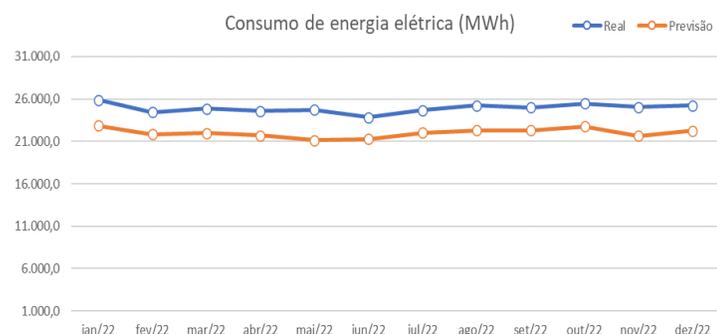
Foram identificadas três categorias de séries de demanda de energia autocorrelacionadas, que foram normalizadas entre -1 e 1. Essas categorias incluem os dados usados para treinar a rede, os dados de validação e os dados de teste. Durante o treinamento, os dados de validação foram empregados para avaliar a eficácia e a capacidade de generalização da rede, enquanto os dados de teste foram usados para avaliar o desempenho da rede em relação a dados desconhecidos.

O conjunto de dados contém 1250 linhas com informação de consumo de energia elétrica, sendo 70% da série utilizada para o treinamento e os 30% restantes foram destinados à validação e teste. Para o treinamento, foi desenvolvido um script em Python na plataforma Jupyter notebook.

Para realizar uma comparação entre os resultados, a seleção dos dados de entrada considerou os primeiros três intervalos de atraso da série original. Durante o treinamento da rede multiobjetivo, foi realizado o controle da complexidade das redes por meio da minimização simultânea do erro para os padrões de treinamento e da norma do vetor de pesos.

No modelo atual, foi utilizado um grande número de neurônios para permitir que o processo de otimização variasse de um modelo menos complexo até um mais complexo. Por essa razão, foi selecionado inicialmente um total de 15 neurônios para a camada escondida. Com esse cenário, a Figura 7 apresenta a performance do modelo, a linha em azul representa os valores reais, enquanto a laranja representa a previsão. O resultado obtido do modelo com 15 neurônios, apresenta um erro absoluto médio de 11,8%.

Figura 7 - Modelo com 15 neurônios

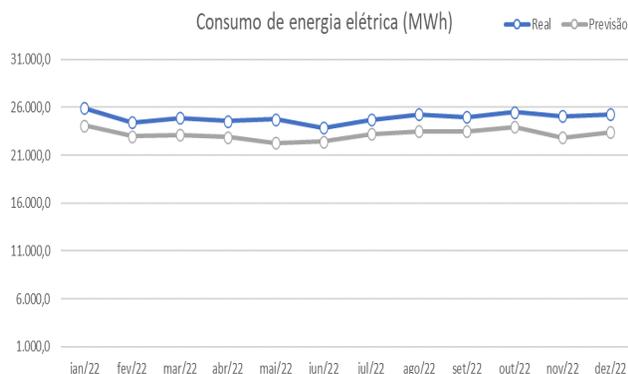


Fonte: Autor

Durante os testes realizados, verificou-se que, para os dados utilizados neste estudo, era necessário utilizar um número mais elevado de neurônios, como 40, a fim de obter soluções que se aproximassem mais dos dados reais.

Dado esse novo cenário, a Figura 8 apresenta a performance da RNA com 40 neurônios, a linha em azul representa os valores reais, enquanto a cinza representa a predição. Com isso, o modelo obteve um erro absoluto médio de 7,2%.

Figura 8 - Modelo com 40 neurônios



Fonte: Autor

Na Tabela 3, é possível observar que quanto maior o número de neurônios na camada escondida, maior a precisão do modelo:

Tabela 3 - Resultados para RNAs

Indicador de performance	15 neurônios	40 neurônios
MAPE (%)	11,8	7,2
MAE (MWh)	2950,6	1793,8

Fonte: Autor

Foram feitos novos testes com 60 neurônios nas camadas intermediárias, porém o modelo apresentou *overfitting*. Quanto maior o número de neurônios na camada escondida, mais complexo é o modelo e mais informações podem ser extraídas dos dados de entrada.

Em geral, aumentar o número de neurônios na camada escondida pode melhorar a precisão do modelo, especialmente se os dados de entrada forem complexos ou se houver muitas características a serem aprendidas. No entanto, é importante lembrar que quando foi realizado o teste com 60 neurônios o modelo apresentou *overfitting*.

6. CONCLUSÕES

A previsão de demanda energética é uma tarefa complexa que envolve a análise de diversos fatores, como condições climáticas, sazonalidade, comportamento dos usuários e mudanças regulatórias. Por essa razão, as empresas e organizações do setor energético precisam de ferramentas eficazes para realizar previsões precisas e confiáveis da demanda por energia. Nesse contexto, o perceptron multicamadas surge como uma opção promissora para a previsão de demanda energética.

Foi proposta uma metodologia para previsão de demanda de energia elétrica no estado de São Paulo, a qual consistiu na criação de bases de dados com séries históricas de demanda e na aplicação de algoritmos de redes neurais artificiais (RNAs) para realizar as previsões. Os resultados indicaram que o aumento do número de neurônios nas camadas intermediárias pode levar ao crescimento da eficácia de previsões. No entanto, ao se empregar topologias com 40 neurônios, foram obtidos resultados satisfatórios, com erros percentuais médios absolutos de 7,2% para a demanda prevista, um resultado satisfatório.

No entanto, é importante ressaltar que sempre há espaço para melhorias e refinamentos na arquitetura e algoritmo utilizados no modelo de RNA. Existem diversas técnicas que podem ser usadas para melhorar o desempenho do modelo, como a escolha de uma arquitetura mais adequada, a modificação dos parâmetros do modelo.

6 REFERÊNCIAS

- [1] ZHANG, G.P. (2012). Neural Networks for Time-Series Forecasting. In: Rozenberg, G., Bäck, T., Kok, J.N. (eds) Handbook of Natural Computing. Springer, Berlin, Heidelberg.
- [2] WANG, Y. (2019). Short-Term Load Forecasting Based on Deep Neural Networks Using LSTM Layer.
- [3] GONEN, T. RAMIREZ-ROSADO, I. Review of distribution system planning models: a model for optimal multi-stage planning. Proceedings of the IEE - Part C. v. 1, n. 1, p. 397 - 408, 1986
- [4] CHOLAKOVA, A. Short-Term Load Forecasting with Artificial Neural Networks in Distribution Systems. Revista Energias, 2019
- [5] KIM, H. Forecasting of Electric Power Demand Using Artificial Neural Networks and Multiple Regression Analysis in the Manufacturing Industry. Applied Sciences., 2021
- [6] MITCHELL, T. Machine Learning. McGraw Hill, 1997, cap 4
- [7] BISHOP, C. M. Neural Networks for Pattern Recognition. Oxford University Press, 2005, cap 3 e 4
- [8] HORNIK, K. Approximation Capabilities of Multilayer Feedforward Networks. Neural Networks v.4, p. 251-257, 1991
- [9] CARDON, A. e MULLER, D. N. (1994). Introdução às redes neurais artificiais. Universidade Federal do Rio Grande do Sul - Instituto de Informática - Curso de PósGraduação em Ciência da Computação
- [10] CASTRO, L. N. d. e ZUBEN, F. J. V. (2015). Redes Neurais Artificiais - O Neurônio Genérico em RNAs. Universidade Estadual de Campinas - Departamento de Engenharia de Computação e Automação Industrial.
- [11] Disponível em: <https://ccee.org.br>. Acesso em: 26 dez. 2022.
- [12] BRAGA, A., P.; CARVALHO, A., P., L.; LUDERMIR, T.,

- B. Redes Neurais Artificiais: Teoria e Aplicações. 2ª ed. LTC, Rio de Janeiro, 2011.
- [13] VELLASCO, M. M. B. R. (2007). Redes Neurais Artificiais. Pontifícia Universidade Católica
- [14] SOARES, P. L. B. e SILVA, J. P. d. (2011). Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica. Revista Brasileira de Computação Aplicada (ISSN 2176-6649), Passo Fundo, v.3, n.2, p.58-72.
- [15] TONSIG, S. L. (2000). Redes Neurais Artificiais Multicamadas e o Algoritmo Backpropagation. Universidade de São Carlos - Gerência de Sistemas de Informação Pontifícia Universidade Católica.