



UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"

Faculdade de Engenharia e Ciências (FEC) - Câmpus de Rosana

**Mariana Valentim**

**Previsão de Cargas Elétricas em Curto Prazo via Redes Neurais *Perceptron*  
Multicamadas**

Rosana – SP

2023

**Mariana Valentim**

**Previsão de Cargas Elétricas em Curto Prazo via Redes Neurais *Perceptron*  
Multicamadas**

Trabalho de Conclusão de Curso apresentado à  
Coordenadoria de Curso de Engenharia de  
Energia do Câmpus de Rosana, Universidade  
Estadual Paulista “Júlio de Mesquita Filho”,  
como parte dos requisitos para obtenção do  
diploma de Graduação em Engenharia de  
Energia.

Orientador: Prof. Dr. Lucas Teles de Faria

Rosana – SP  
2023

V155p Valentim, Mariana  
Previsão de Cargas Elétricas em Curto Prazo via Redes Neurais  
Perceptron Multicamadas / Mariana Valentim. -- Rosana, 2023  
35 p. : tabs.

Trabalho de conclusão de curso (Bacharelado - Engenharia de  
Energia) - Universidade Estadual Paulista (Unesp), Faculdade de  
Engenharia e Ciências, Rosana  
Orientador: Lucas Teles Faria

1. Perceptron Multicamadas. 2. Previsão de Cargas Elétricas. 3.  
Previsão de Demanda. 4. Rede Neural Artificial. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de  
Engenharia e Ciências, Rosana. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

**MARIANA VALENTIM**

ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO  
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE

**“GRADUADO EM ENGENHARIA DE ENERGIA”**

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE  
CURSO DE GRADUAÇÃO EM ENGENHARIA DE ENERGIA

Prof. Dr. Leandro Ferreira Pinto

Coordenador

**BANCA EXAMINADORA:**

Prof. Dr. Lucas Teles de Faria

Orientador, FEC-UNESP, Câmpus Rosana

Prof. Dr. Leonardo Henrique Faria Macedo Possagnolo

FEC-UNESP, Câmpus Rosana

Profa. Dra. Maria Claudia Costa de Oliveira Botan

FEC-UNESP, Câmpus Rosana

Novembro de 2023

## **AGRADECIMENTOS**

Gostaria de expressar minha profunda gratidão a todas as pessoas e instituições que tornaram possível a conclusão deste trabalho. Este projeto representa um marco significativo na minha jornada acadêmica e não teria sido possível sem o apoio inestimável de muitas pessoas e organizações.

Primeiramente, quero agradecer aos meus pais, ao qual dedico todo este trabalho pois, desde o início da minha educação, investiram amor, confiança e incentivo inabalável em cada etapa da minha vida. Sem o apoio de vocês, este trabalho não teria sido concretizado. Vocês são a fonte da minha inspiração e determinação.

Em especial a minha mãe que sempre foi a minha principal incentivadora e apoiadora.

Aos meus amigos e familiares, que estiveram ao meu lado durante toda essa jornada, obrigada por compreenderem os momentos de ausência e por dedicarem seu tempo e carinho para me apoiar. Suas palavras de encorajamento e paciência foram fundamentais.

Agradeço à respeitada instituição Unesp por fornecer o ambiente acadêmico propício para o desenvolvimento deste trabalho. A infraestrutura, recursos e corpo docente exemplar da universidade foram fundamentais para minha formação acadêmica.

Não poderia deixar de mencionar meu orientador, Lucas Teles cuja orientação e apoio foram cruciais. Sua experiência, dedicação e disposição para compartilhar conhecimento foram inestimáveis. Obrigado por investir tempo e energia no meu crescimento acadêmico e profissional.

Este trabalho é um reflexo do esforço coletivo e do apoio que recebi de tantas pessoas e instituições. Cada um de vocês teve um papel importante nessa jornada, e sou profundamente grata.

Por fim, quero expressar minha sincera gratidão a todos que de alguma forma contribuíram para este trabalho. A todos vocês, meu muito obrigado.

## RESUMO

A previsão de cargas elétricas é um procedimento de suma importância para os sistemas elétricos de potência e consiste na estimativa do consumo de energia elétrica futuro. Ela é vital para determinar quando e quanto de capacidade de geração e de transmissão deve-se dispor para atender a carga prevista sem interrupções no fornecimento. Ademais, a previsão de demanda ou previsão de carga de longo, médio, curto e curtíssimo prazo é um insumo para diversos outros estudos em sistemas elétricos de potência como: planejamento e operação dos sistemas elétricos, despacho econômico, fluxo de potência, análise de estabilidade e outros. Logo, a previsão da demanda deve ser precisa para que o sistema elétrico de potência opere de forma segura e confiável. Assim, neste estudo propõe-se um sistema previsor de cargas elétricas de curto prazo baseado na rede neural artificial *perceptron* multicamadas com entrada dos atrasadas no tempo ou *time delay neural network* – TDNN. O sistema foi testado em um banco de dados real e a eficiência do método preditor foi avaliado via métrica *mean average percentage error* (MAPE).

Neste estudo, a Rede Neural Artificial de Perceptron Multicamadas (RNA-PMC) foi utilizada para prever séries temporais de cargas elétricas em kilowatt-hora (kWh). A RNA-PMC foi treinada com o algoritmo de aprendizagem retropropagação (backpropagation) e empregou a arquitetura de rede neural *time delay neural network* (TDNN) para prever as séries temporais reais de cargas elétricas em kWh. A aplicação desse método em dois estudos de caso resultou em sucesso na previsão, com Erro Percentual Absoluto Médio (MAPE) de 0,546% e 5,476%, respectivamente, destacando a eficácia da RNA-PMC na predição precisa de padrões em séries temporais de consumo elétrico.

**Palavras-Chaves:** Perceptron Multicamadas; Previsão de Cargas Elétricas; Previsão de Demanda; Rede Neural Artificial

## ABSTRACT

Electrical load forecasting is an extremely important procedure for electrical power systems and consists of estimating future electrical energy consumption. It is vital to determine when and how much generation and transmission capacity should be available to meet the expected load without adequate interruptions. Furthermore, demand forecasting or long-, medium-, short-and very short-term load forecasting is an input for several other studies in electrical power systems such as: planning and operation of electrical systems, economic dispatch, power flow, power analysis, stability and others. Therefore, demand forecasting must be accurate for the electrical power system to operate safely and reliably. Therefore, this study proposes a short-term electrical load forecasting system based on the multilayer perceptron artificial neural network with time delay neural network input – TDNN. The system was tested on a real database and the efficiency of the predictor method was evaluated using the mean percentage error (MAPE) metric.

In this study, the Multilayer Perceptron Artificial Neural Network (MLP-ANN) was employed to predict time series of electrical loads measured in kilowatt-hours (kWh). The MLP-ANN was trained using the backpropagation learning algorithm and employed the time delay neural network (TDNN) architecture to forecast the actual time series of electrical loads in kWh. The application of this method in two case studies resulted in successful prediction, with Mean Absolute Percentage Error (MAPE) values of 0.546% and 5.476%, respectively, highlighting the effectiveness of the MLP-ANN in accurately predicting patterns in time series of electrical consumption.

**Keywords:** Artificial Neural Network; Demand Forecast; Load Forecast; Multilayer Perceptron

## LISTA DE FIGURAS

|                                                                                              |           |
|----------------------------------------------------------------------------------------------|-----------|
| <i>Figura 1 – Consumo por classes de consumidores. ....</i>                                  | <i>10</i> |
| <i>Figura 2 – Tipos de previsão de cargas elétricas. ....</i>                                | <i>15</i> |
| <i>Figura 3 – Fatores que influem na demanda por energia elétrica. ....</i>                  | <i>16</i> |
| <i>Figura 4 – Condições fundamentais para o processo de previsão de carga. ....</i>          | <i>16</i> |
| <i>Figura 5 – Neurônio artificial de McCulloch-Pitts. ....</i>                               | <i>18</i> |
| <i>Figura 6 – Estrutura da rede neural perceptron multicamadas. ....</i>                     | <i>20</i> |
| <i>Figura 7 – Rede neural feedforward com não linearidade sigmoide. ....</i>                 | <i>23</i> |
| <i>Figura 8 – Estrutura da rede PMC com entradas atrasadas no tempo. ....</i>                | <i>25</i> |
| <i>Figura 9 – Fluxograma da metodologia proposta. ....</i>                                   | <i>25</i> |
| <i>Figura 10 – Erro quadrático médio após cada época de treinamento da rede neural. ....</i> | <i>27</i> |
| <i>Figura 11 – Carga real versus carga prevista para o primeiro estudo de caso. ....</i>     | <i>28</i> |
| <i>Figura 12 – Carga real versus carga prevista para o segundo estudo de caso. ....</i>      | <i>32</i> |

## LISTA DE TABELAS

|                                                                                           |           |
|-------------------------------------------------------------------------------------------|-----------|
| <i>Tabela 1 – Parâmetros aplicados nas simulações do estudo de caso 1. ....</i>           | <i>28</i> |
| <i>Tabela 2 – Codificação binária para os dias da semana. ....</i>                        | <i>31</i> |
| <i>Tabela 3 – Codificação binária para as horas do dia.....</i>                           | <i>31</i> |
| <i>Tabela 4 – Parâmetros aplicados nas simulações para o segundo estudo de caso. ....</i> | <i>32</i> |

## SUMÁRIO

|                                                                  |           |
|------------------------------------------------------------------|-----------|
| <b>1. INTRODUÇÃO</b>                                             | <b>10</b> |
| 1.1. <i>Objetivos</i>                                            | 11        |
| 1.2. <i>Estrutura do Trabalho</i>                                | 11        |
| <b>2. REVISÃO DA LITERATURA</b>                                  | <b>12</b> |
| <b>3. PREVISÃO DE CARGAS ELÉTRICAS</b>                           | <b>14</b> |
| <b>4. REDES NEURAIS ARTIFICIAIS</b>                              | <b>17</b> |
| 4.1. <i>Neurônio Artificial</i>                                  | 18        |
| 4.2. <i>Rede Neural Artificial Perceptron Multicamadas</i>       | 19        |
| 4.2.1. <i>Processo de Treinamento da Perceptron Multicamadas</i> | 19        |
| 4.2.2. <i>Algoritmo de Treinamento Backpropagation</i>           | 20        |
| <b>5. METODOLOGIA</b>                                            | <b>24</b> |
| 5.1. <i>Previsão de Demanda de Energia Elétrica</i>              | 24        |
| 5.2. <i>Análise do Desempenho do Sistema Previsor</i>            | 26        |
| <b>6. RESULTADOS</b>                                             | <b>27</b> |
| 6.1. <i>Primeiro Estudo de Caso</i>                              | 27        |
| 6.1.1. <i>Descrição da Base de Dados</i>                         | 27        |
| 6.1.2. <i>Previsão de Cargas Elétricas</i>                       | 27        |
| 6.2. <i>Segundo Estudo de Caso</i>                               | 29        |
| 6.2.1. <i>Descrição da Base de Dados</i>                         | 29        |
| 6.2.2. <i>Codificação das Entradas da Rede Neural</i>            | 29        |
| 6.2.3. <i>Previsão da Demanda</i>                                | 29        |
| <b>7. CONCLUSÕES</b>                                             | <b>33</b> |
| <b>8. REFERÊNCIAS</b>                                            | <b>34</b> |


## 1. INTRODUÇÃO

A previsão de cargas elétricas ou previsão de demanda desempenha um papel fundamental na gestão e no planejamento eficiente dos sistemas elétricos de potência. Ela consiste na estimativa da demanda futura de energia elétrica. Com o crescimento populacional, o aumento das tecnologias e o surgimento de economias emergentes, tem-se observado um aumento significativo na demanda por energia elétrica em todo o mundo (MENEZES *et al.*, 2014). Nesse sentido, as previsões de demanda de energia são cruciais para garantir que haja energia suficiente para atender à demanda dos consumidores. Nesse sentido, a Figura 1 apresenta o consumo médio de eletricidade por classes de consumidores: residencial, comercial e industrial.

Com o desenvolvimento ao longo dos anos, o consumo de energia elétrica aumentou exponencialmente. Levando em consideração que a humanidade está totalmente atrelada à eletricidade para quase todas as suas ações básicas, seja na saúde, alimentação, trabalho, estudo e até mesmo no lazer, com todo esse cenário, há a necessidade de um monitoramento para o planejamento da expansão da geração e a construção de novas linhas de transmissão e de distribuição de energia elétrica.

A evolução mostrou que a falta de monitoramento não poderia existir. Sendo assim, a previsão de carga se faz necessária. Existem períodos com picos de consumo onde a previsão se mostra mais eficaz, como nos feriados, férias e finais de semana, ou em situações de greve, onde uma grande população está em casa e consome mais energia. Também existem as condições meteorológicas que podem influenciar a distribuição de energia. Com isso, pode-se antecipar uma sobrecarga na rede elétrica.

Figura 1 – Consumo por classes de consumidores.



Fonte: EPE (2023).

Se faz necessário o monitoramento da rede para assim evitar que o consumo fique oscilante ou até mesmo que apagões ocorram. A previsão de carga se mostra um monitoramento eficaz, levando em consideração que esse acompanhamento previne problemas futuros. Há também um benefício econômico, pois o mercado de energia precisa ter um acompanhamento contínuo. O método para previsão de cargas elétricas deve ser rápido. Sendo assim, as redes neurais artificiais (RNAs) são viáveis e aplicadas recorrentemente. Elas foram desenvolvidas inspiradas no funcionamento do neurônio biológico com entradas, conexões e saída.

A RNA é inspirada em padrões do cérebro humano, tendo como principal foco a melhoria e a minimização dos “erros”. Mesmo com a eliminação de alguns neurônios a rede neural não é seriamente afetada, pois há um aumento constante da capacidade de aprendizagem e armazenamento distribuído da informação aprendida.

### **1.1. Objetivos**

Este estudo aplica a rede neural *perceptron* multicamadas (PMC) com o algoritmo de treinamento de retropropagação ou *backpropagation* para previsão de cargas elétricas de curto prazo a nível de horas.

### **1.2. Estrutura do Trabalho**

Este trabalho está dividido em sete capítulos. Este capítulo de introdução apresentou uma visão geral sobre a previsão de demanda via RNAs.

O capítulo 2 contém uma revisão da literatura especializada sobre previsão de cargas elétricas.

O capítulo 3 aborda a previsão de cargas elétricas, que consiste em um processo em que se estima o consumo de energia elétrica de um determinado sistema ou região.

No capítulo 4, abordam-se as RNAs, o neurônio artificial e seu funcionamento, com o enfoque para a rede neural PMC, com foco nas suas estruturas: camada de entrada, camadas ocultas e camada de saída. Abordam-se também o tipo de treinamento e suas vantagens e desvantagens.

No capítulo 5 são apresentados os detalhes da metodologia proposta.

O capítulo 6 contém os resultados deste estudo obtidos via MATLAB.

Finalmente, no capítulo 7 são apresentadas as conclusões e as contribuições deste estudo.

## 2. REVISÃO DA LITERATURA

Neste capítulo são apresentados estudos relacionados à previsão de cargas elétricas, abordando diferentes métodos e técnicas utilizadas para estimar a demanda de energia em diversos contextos.

Morais (2022) propôs uma avaliação aplicando diferentes modelos de RNAs para resolução do problema de previsão de carga de curto prazo. A metodologia envolveu a aplicação de técnicas como *perceptron* multicamadas onde foram implementadas diversas camadas, de redes neurais recorrentes *long-short term memory* (LSTM) e *gated recurrent unit* (GRU). O processo de treinamento das RNAs foi realizado considerando dados histórico de carga e temperatura. O desempenho dos modelos de previsão foi avaliado por meio da aplicação da métrica *mean average percentage error* (MAPE), que atingiu um valor abaixo de 2,3% para os diferentes conjuntos de testes.

A RNA ARTMAP Euclidiana foi aplicada por Ferreira (2020) ao problema de previsão de cargas elétricas de modo multinodal a curto prazo. Diferentemente da previsão global, a previsão multinodal consiste na previsão da demanda para várias barras ou entre os diversos pontos da rede elétrica. O sistema predictor proposto é composto por vários módulos nos quais foram realizadas previsões independentes para nove subestações. Os dados históricos de cargas elétricas e um conjunto de elementos exógenos compuseram o conjunto de entradas da RNA. Os MAPES obtidos para as nove subestações foram inferiores a 3,5%, sendo que 8 alcançaram resultados inferiores a 2% demonstrando que a proposta foi promissora.

Em Gomes (2017) foi aplicada a RNA ARTMAP Euclidiana para previsão de carga global a curto prazo, tendo como principal objetivo a determinação da demanda de energia elétrica para as próximas 24 horas. Para isso, utilizou-se um conjunto de dados históricos de consumo provenientes de uma companhia elétrica localizada na Espanha, que foram empregados no treinamento e na avaliação da metodologia proposta, considerando três cenários com diferentes horizontes de treinamento. O primeiro caso envolveu um conjunto de dados composto por 744 observações, enquanto o segundo e terceiro casos contaram com 1464 e 2208 observações, respectivamente. O MAPE obtido para os três cenários foi inferior a 1,60%.

Brangioni (2023) realizou a previsão de cargas elétricas aplicando uma RNA convolucional. Os dados utilizados foram extraídos do site da Empresa de Pesquisa Energética (EPE). Esses dados continham o histórico de consumo mensal de janeiro de 2004 até junho de 2020, abrangendo níveis nacional, regional e por subsistemas. O estágio de treinamento foi conduzido aplicando 70% dos dados, enquanto os 30% restantes foram reservados para o estágio de teste, com o objetivo de medir e avaliar a eficiência do sistema de previsão.

A previsão de cargas elétricas de curto prazo foi realizada por Guelfi e Decanini (2023). O sistema predictor foi baseado em três arquiteturas distintas de RNAs: rede LSTM, rede *encoder-decoder* LSTM e rede *encoder-decoder* CNN-LSTM. A técnica consiste de quatro etapas: (i) Aquisição de dados, (ii) pré-processamento das informações e janelamento, (iii) Aplicação das RNAs e (iv) previsão de carga com um passo de 24 horas à frente. Os resultados obtidos são satisfatórios com um MAPE inferior a 4% para as três arquiteturas implementadas.

Uma técnica baseada em *support vector machines* (SVMs) foi apresentada por Nogueira e Salgado (2013) para previsão da demanda de energia para os próximos 12 meses. O principal objetivo dos autores foi comparar diferentes modelos de previsão para avaliar seu comportamento e eficiência, bem como o impacto dessas estratégias no erro de previsão. Para isso, foram introduzidas duas estratégias de previsão. A primeira consistiu na obtenção da curva diária através da previsão de cada hora individualmente. Por outro lado, a segunda lineariza os dados para obter a curva diária através de um único modelo. A eficiência da técnica foi avaliada através da aplicação de diferentes cenários, visando entender o desempenho dos previsores em diversas situações, que incluem três séries temporais com períodos distintos. O MAPE obtido para as três séries foi inferior a 2,87%.

Garcia (2013) apresentou uma avaliação de métodos de previsão de cargas elétricas onde foram estudadas várias técnicas. O principal objetivo foi avaliar qual técnica apresenta os melhores resultados com relação à previsão de demanda de curtíssimo prazo. Três métodos foram introduzidos: RNA Elman, RNA NARX e *neurofuzzy*. Diversas compuseram os dados de entrada: temperatura, hora, minuto, corrente, potência ativa para dias úteis e dias não úteis.

### 3. PREVISÃO DE CARGAS ELÉTRICAS

A previsão de demanda é vital para determinar quando e quanto de capacidade de geração e de transmissão deve-se dispor para atender a carga prevista sem interrupções no fornecimento. Além disso, a previsão de demanda é crucial para execução de diversos outros estudos em sistemas elétricos de potência como: planejamento e operação dos sistemas elétricos, despacho econômico, fluxo de potência e análise de estabilidade.

A previsão de demanda envolve estimar a necessidade futura de energia elétrica. Devido à sua natureza estocástica, o valor exato da demanda de energia elétrica para o futuro não pode ser determinado. Portanto, as previsões são realizadas com um nível de incerteza aceitável (MELO, 2010).

A demanda de energia elétrica pode ser classificada como um processo estocástico, não estacionário, composta por diversos componentes e cujo comportamento é influenciado por diversos fatores: temporárias, climáticos, aleatórios e sazonais (MELO, 2010).

Conforme a Figura 2, a previsão de carga divide-se em quatro principais categorias: longo prazo, médio prazo, curto prazo e curtíssimo prazo. A previsão de longo prazo corresponde àquela implementada principalmente para o planejamento dos sistemas elétricos, onde se leva em consideração um período de 10 a 20 anos. Nessa categoria de previsão, os dados aplicados para a previsão correspondem à aplicação de tendências e consumo a longo prazo (LOPES, 2005).

A previsão de carga a médio prazo refere-se à estimativa da demanda de energia elétrica em um período que abrange poucas semanas ou até mesmo alguns anos. Aplicada para o planejamento de suprimentos e programas de manutenção, ela desempenha um papel importante na operação eficiente e confiável dos sistemas elétricos, uma vez que auxilia as empresas de energia no planejamento da geração e distribuição de energia (LOPES, 2005; MACHADO, 2015).

A previsão de curto prazo, consiste na estimativa de carga elétrica para um período relativamente pequeno, normalmente variando algumas horas a semanas. Nesta categoria, estima-se a carga para cada hora do dia, pico de carga diária, geração de energia diária ou semanal. Assim, nela ocorre o planejamento das operações econômica e de segurança diária do sistema elétrico.

Em último, as previsões de curtíssimo prazo envolvem a estimativa de carga para poucas horas do sistema ou em menos de quinze minutos. Esse tipo de previsão é muito utilizada para o planejamento de operação *online* e controle, que em geral incluem esse tipo de análise (FERREIRA, 2020; LOPES, 2005).

Figura 2 – Tipos de previsão de cargas elétricas.




Fonte: Adaptado de Garcia (2013).

Segundo O'Donovan (1983) e conforme apresentado na Figura 3, vários fatores influenciam uma carga elétrica e seu comportamento, dentre esses fatores destacam-se:


- ❖ *Fatores climáticos*: os fatores climáticos incluem a temperatura, umidade relativa do ar, o nível de luminosidades e a velocidade do vento. Estes fatores exercem uma influência no comportamento da carga elétrica, principalmente, em áreas residenciais. Geralmente a variável mais utilizada é a temperatura.
- ❖ *Fatores cíclicos ou temporais*: são fatores que se repetem como dias, semanas, meses até mesmo um ano, levando em consideração também feriados que são épocas que existem variações na periodicidade, onde se tem uma baixa demanda de eletricidade nos finais de semana e uma alta demanda para os dias úteis. Na periodicidade anual tem-se a mudança de estação ao longo do ano. Por outro lado, a ocorrência de feriados diminui os valores de carga em relação aos dias comuns.
- ❖ *Fatores atípicos ou aleatórios*: nesta categoria citam-se as greves ou mesmo uma transmissão de programa de TV de interesse geral.

Figura 3 – Fatores que influem na demanda por energia elétrica.



Fonte: Adaptado de Garcia (2013).

Figura 4 – Condições fundamentais para o processo de previsão de carga.



Fonte: Adaptado de Lopes (2005).

As cargas elétricas são constituídas por diversos equipamentos e divididas em três principais classes, conforme apresentado na Figura 1: residenciais, comerciais e industriais. Elas são conformadas por vários aparelhos e dispositivos, que, quando analisados em conjunto, apresentam tendências que podem ser previstas. Portanto, alguns fatores importantes devem ser levados em consideração no processo de previsão, como o comportamento da carga e a análise de fatores que interferem em sua modelagem (LOPES, 2005).

A previsão de carga pode ser feita de várias maneiras, existindo diversas técnicas disponíveis para esse fim desde que satisfeitas as condições da Figura 4.

#### 4. REDES NEURAIS ARTIFICIAIS

As RNAs possuem uma notável capacidade computacional, derivada tanto da sua estrutura altamente paralela e distribuída, quanto da habilidade de aprender e, por consequência, generalizar. Dois aspectos fundamentais as tornam semelhantes ao cérebro. O primeiro corresponde ao conhecimento adquirido da rede obtido através do seu ambiente por meio de um processo denominado treinamento ou aprendizagem; segundo a força das conexões entre neurônios, representada pelos pesos sinápticos, que é essencial para o armazenamento desse conhecimento (HAYKIN, 2007).

A estrutura das RNAs é composta por três tipos de camadas: camada de entrada, camada intermediária ou escondida e camada de saída; cada uma contendo unidades de processamentos (neurônios) interconectados. À camada de entrada são fornecidos os dados de entrada: sinais, características ou medições injetadas. A camada intermediária desempenha um papel importante no processo de aprendizagem, sendo capaz de extrair características de ordem complexa. Por fim, a camada de saída, responsável pela geração e apresentação dos resultados. Por intermédio de ramificações, as saídas podem ser utilizadas como entrada do próprio neurônio ou de outros neurônios. Em cada conexão, há um peso sináptico associado.

O número de entradas e saídas está relacionado com a dimensionalidade dos dados; por outro lado, a quantidade de neurônios nas camadas intermediárias é determinada pela complexidade do problema estudado. Ressalta-se que um excesso de neurônios nessas camadas pode resultar em resultados ineficientes (REZENDE, 2003).

A seguir são apresentadas as principais características das RNAs (HAYKIN, 2007; SILVA, SPATTI, FLAUZINO, 2016):


- ❖ *Capacidade de generalização*: corresponde à habilidade da RNA produzir saídas adequadas para um determinado conjunto de entradas que não fazem parte do conjunto de dados de treinamento original.
- ❖ *Capacidade de aprendizado*: uma propriedade fundamental das RNAs. Consiste na aplicação de um algoritmo de treinamento cujo objetivo é ajustar os pesos sinápticos. Isso possibilita que a rede extraia e compreenda os relacionamentos entre as diversas variáveis que compõem o problema em estudo.
- ❖ *Adaptabilidade*: uma das características distintivas das redes neurais é a sua capacidade inerente de se adaptar. Elas possuem a competência particular de realizar adaptações em seus pesos. Portanto, uma rede treinada para atuar em um determinado ambiente, pode ter facilmente seu processo de treinamento reiniciado para lidar com possíveis mudanças estruturais nas condições operacionais desse ambiente.

- ❖ *Tolerância a falhas:* as RNAs possuem um alto nível de interconexões entre seus neurônios, com isso torna-se um sistema tolerante a falhas quando parte de suas estruturas são sensivelmente corrompidas.

#### 4.1. Neurônio Artificial

O neurônio artificial desempenha um papel fundamental na operação das redes neurais, sendo responsável pelo processamento de informações com capacidade de armazenamento, podendo apresentar comportamento tanto linear quanto não linear. Na Figura 5, é apresentado o modelo concebido por McCulloch e Pitts (1943), que foi pioneiro nesse campo e é o modelo mais conhecido na literatura (HAYKIN, 2007). Esse modelo, que se tornou a base para o desenvolvimento posterior das RNAs, demonstra como a estrutura de um neurônio artificial pode ser utilizada para realizar cálculos complexos a partir de várias entradas.

Figura 5 – Neurônio artificial de McCulloch-Pitts.



Fonte: Adaptado de Haykin (2007).

A camada de entrada desempenha um papel crucial ao receber e processar os dados de entrada ( $x_1 \ x_2 \dots x_n$ ). Cada uma das respectivas entradas é então multiplicada por um peso correspondente denotado por ( $w_1 \ w_2 \dots w_n$ ). Os pesos neurais são inicialmente atribuídos de forma aleatória e são responsáveis pela ponderação dos sinais de entradas. Além disso, a rede possui um peso denominado bias ( $w_0$ ), que é responsável por ajustar o aumento ou redução da entrada na função de ativação.

A combinação linear ( $\Sigma$ ) é responsável por agregar todos os sinais de entrada, após a multiplicação dos pesos neurais pelos sinais de entrada resultando no cálculo do potencial de ativação –  $u$ .

A função de ativação ( $F_s$ ), por sua vez, é responsável por ativar o neurônio. Ela age também como uma função restritiva, limitando o intervalo permissível da amplitude de saída do neurônio. As funções de ativação mais comumente empregadas incluem a função degrau e a função sigmoide. Para este estudo, será aplicada a função sigmoide. Por fim, a saída ( $y$ ) da RNA pode representar a resposta final ou servir como entrada para outros neurônios, possibilitando a realização de operações mais complexas.

#### 4.2. Rede Neural Artificial Perceptron Multicamadas


A PMC é uma classe fundamental de redes neurais, destacando-se pela sua eficácia na resolução de problemas complexos em diversas áreas. Ela é caracterizada por uma ou duas camadas intermediárias, conforme ilustrado na Figura 6. Sua estrutura é composta por três tipos distintos de camadas de neurônios: a camada de entrada, a camada oculta ou intermediária e a camada de saída. A camada de entrada é formada por um conjunto de unidades sensoriais responsáveis por receber os dados iniciais. Os neurônios da camada oculta, posicionada entre as camadas de entrada e saída, desempenham um papel crucial no processo de aprendizado de tarefas complexas, permitindo a extração gradual das características mais relevantes dos vetores de entrada. Por fim, na camada de saída, são apresentados os resultados (HAYKIN, 2007).

Conforme apresentado na Figura 6, os sinais recebidos na camada de entrada são propagados progressivamente de camada a camada. Dessa forma, a rede neural PMC possui uma estrutura *feedforward*, na qual o fluxo de informações segue da entrada para a saída, sem a existência de laços de realimentação entre as camadas.

##### 4.2.1. Processo de Treinamento da Perceptron Multicamadas

Uma das características distintivas das redes neurais é a capacidade de aprendizado, o que permite aprimorar seu desempenho por meio de um processo denominado como treinamento ou aprendizagem. Na RNA PMC, o processo de treinamento, no qual ocorre o ajuste das matrizes de pesos, é realizado de forma supervisionada. Portanto, para cada amostra de entrada, há uma saída desejada associada.

O processo de treinamento é realizado por meio do algoritmo *backpropagation* ou algoritmo de retropropagação de erro apresentado por Rumelhart *et al.* (1986). Ele é baseado na aplicação da regra de aprendizagem por correção do erro que envolve dois passos: propagação e retropropagação. O primeiro passo é a etapa de propagação, na qual os valores de entrada são introduzidos nos nós sensoriais da rede e sua influência se propaga de camada para camada. Geralmente, os pesos iniciais têm valores pequenos e aleatórios; durante esse processo, os pesos sinápticos permanecem fixos. Por fim, um conjunto de saídas é gerado como resposta da rede neural.

Figura 6 – Estrutura da rede neural *perceptron* multicamadas.

Fonte: Adaptado de Silva, Spatti e Flauzino (2016).

A segunda etapa consiste na retropropagação ou *backward*, na qual os pesos sinápticos dos neurônios são atualizados através da aplicação da regra de correção de erro. Por meio de interações, os pesos são atualizados automaticamente, onde ocorre a redução gradual das somas dos erros, resultantes da diferença entre a resposta fornecida pela rede e a saída desejada correspondente. Esse processo iterativo de ajuste é fundamental para o aprendizado efetivo da rede neural.

#### 4.2.2. Algoritmo de Treinamento *Backpropagation*

A seguir apresenta-se o algoritmo de treinamento *backpropagation*. Essa abordagem foi introduzida com intuito de torná-lo mais eficiente (WIDROW; LEHR, 1990; MINUSSI, 2008; SILVA; SPATTI; FLAUZINO, 2016).

*Etapa 1 – Definição dos parâmetros:* o primeiro passo consiste em definir todos os parâmetros da RNA, enumerados a seguir:

- ❖ *Quantidade de neurônios da camada de entrada.* A definição da quantidade de neurônios na camada de entrada está diretamente relacionada à dimensionalidade dos dados. Por exemplo, se o problema consiste em um vetor de entrada contendo 3 elementos, representado por  $X = [x_1 \ x_2 \ x_3]$ , então recomenda-se  $N_E = \text{dimensão}(X)$ .
- ❖ *Quantidade de neurônios a camada intermediária.* Pode ser determinado empiricamente por meio de testes e avaliação da eficácia da rede variando o número de neurônios. É importante destacar que um excesso de neurônios pode levar a resultados insatisfatórios.

- ❖ *Quantidade de neurônios da camada de saída.* A determinação da quantidade de neurônios na camada de saída está diretamente ligada à dimensionalidade dos dados.  $N_s = \text{dimensão}(Y)$ .
- ❖ *Taxa de treinamento:*  $0,05 \leq \alpha \leq 0,75$ .
- ❖ *Tolerância.* Limite aceitável para o erro entre a saída predita pela rede e a saída desejada. Uma vez que essa condição é atendida, a rede é considerada treinada e está pronta para realizar inferências ou previsões em novos dados.
- ❖ *Número máximo de época.:* Refere-se ao limite de iterações ou passos de treinamento que serão realizados durante o processo de aprendizado da rede. Uma época completa ocorre quando todas as amostras de treinamento pertencentes ao conjunto de dados foram apresentadas à rede uma vez. A especificação desse parâmetro é importante, uma vez que evita que o treinamento continue indefinidamente, especialmente quando, durante o processo de treinamento, não se consegue obter um erro menor do que a tolerância especificada.

*Etapa 2 – Definição da função de ativação ( $g$ ).* Introduz não linearidades na rede, permitindo que ela aprenda e represente relações complexas nos dados.

*Etapa 3 – Ponderação do vetor de entrada.* Nessa etapa é feita a multiplicação do vetor de entrada pelos pesos sinápticos associado a cada amostra de entrada. O vetor  $I_j^{(L)}$  contendo as entradas ponderadas para três camadas pode ser calculado de acordo com as (1) – (3). Sendo  $I$  o vetor de entradas ponderadas e  $j$  é o *jésimo* neurônio da cama  $L$ . Em (1) tem-se o cálculo para a primeira camada.

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \leftrightarrow I_j^{(1)} = W_{1,0}^{(1)} \cdot x_0 + W_{1,1}^{(1)} \cdot x_1 + \dots + W_{1,n}^{(1)} \cdot x_n \quad (1)$$

$$I_j^{(2)} = \sum_{i=0}^{n1} W_{ji}^{(2)} \cdot Y_i^{(1)} \leftrightarrow I_j^{(2)} = W_{1,0}^{(2)} \cdot Y_0^1 + W_{1,1}^{(2)} \cdot Y_1^1 + \dots + W_{1,n}^{(2)} \cdot Y_{n1}^1 \quad (2)$$

$$I_j^{(3)} = \sum_{i=0}^{n2} W_{ji}^{(3)} \cdot Y_i^{(2)} \leftrightarrow I_j^{(3)} = W_{1,0}^{(3)} \cdot Y_0^{(2)} + W_{1,1}^{(3)} \cdot Y_1^{(2)} + \dots + W_{1,n}^{(3)} \cdot Y_{n2}^{(2)} \quad (3)$$

Em (2) para o cálculo dos vetores  $I_j^{(2)}$ ,  $I_j^{(3)}$  associados às camadas 2 e 3, são introduzidas as saídas dos neurônios da primeira camada. Onde  $Y_j^{(1)} = g(I_j^{(1)})$ ;  $Y_j^{(2)} = g(I_j^{(2)})$  e  $Y_j^{(3)} = g(I_j^{(3)})$ . Sendo  $g$  a função de ativação selecionada.

*Etapa 4 – Cálculo do erro quadrático.* Mensura o desvio entre as respostas produzidas pelos neurônios da camada de saída, em relação às respectivas saídas desejadas. O erro para a *késima* amostra de treinamento pode ser obtido conforme (4).

$$E(k) = \frac{1}{2} \sum_{j=1}^{n3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (4)$$

Sendo  $Y_j^{(3)}(k)$  o valor fornecido pelo *jésimo* neurônio de saída da rede no processo de treinamento da *késima* amostra e  $d_j(k)$  representa sua respectiva saída desejada.

*Etapa 5 – Cálculo do erro quadrático médio.* Nessa etapa, calcula-se por meio de (5) o desempenho global do algoritmo *backpropagation* para um conjunto de treinamento composto por  $p$  amostras.

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (5)$$

*Etapa 6 – Verificação do critério de parada.* Nessa etapa, o critério de parada é avaliado por meio da comparação entre o erro quadrático médio obtido e a tolerância de erro estabelecida *a priori*. Verifica-se também se o algoritmo atingiu a quantidade máxima de épocas especificadas conforme (6).

$$|Erro| \leq \text{tolerância preespecificada ou } NE \geq NEmax \quad (6)$$

Sendo  $NE$  o número de épocas executadas durante o estágio de treinamento, e  $NEmax$  o número de épocas máximo estabelecido.

*Etapa 7 – Atualização dos pesos neurais da camada de saída.* Nessa etapa, inicia-se a atualização dos pesos, uma vez que o critério de parada não foi satisfeito. O processo de retropropagação ou *backward* é iniciado onde, por meio da atualização dos pesos, busca-se a redução gradual do erro quadrático médio em relação ao valor pré-especificado. Assim, efetua-se o ajuste da matriz de pesos  $W_{ji}^{(3)}$  em direção oposta ao gradiente a fim de reduzir o erro conforme (7) – (10):

$$W_{ji}^{(3)} = \alpha \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (7)$$

Sendo  $\delta_j^{(3)}$  o gradiente local em relação ao *jésimo* neurônio da camada de saída, sendo dado por (8).

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (8)$$

Em (9) é apresentada a derivada da função sigmoide, onde  $\lambda$  corresponde a inclinação da função sigmoide.

$$g' = 0.5 \lambda (1 - (Y_j^{(3)})^2) \quad (9)$$

$$W_{ji}^{(3)} = W_{ji(velho)} + \alpha \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (10)$$


Os pesos dos neurônios situados na última camada são atualizados levando-se em consideração o erro produzido pela diferença entre as respostas fornecidas pela rede neural e as respectivas saídas desejadas.

*Etapa 8 – Atualização dos pesos neurais das camadas intermediárias.* Como nessas camadas não se têm os valores desejados para suas saídas, para a realização dos ajustes nos pesos, leva-se em consideração as estimativas dos erros de saída produzidos pelos neurônios imediatamente posteriores, os quais já foram previamente ajustados.

$$\delta_j^{(2)} = \sum_{k=1}^{n3} \delta_j^{(3)} \cdot W_{ji}^{(3)} \cdot g'(I_j^{(2)}) \quad (11)$$

$$W_{ji}^{(2)} = W_{ji(velho)} + \alpha \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (12)$$

Figura 7 – Rede neural *feedforward* com não linearidade sigmoide.



Fonte: Minussi (2008).

## 5. METODOLOGIA

Neste capítulo, será apresentada a metodologia para a previsão de demanda de energia elétrica em curto prazo. Esse processo envolve a estimação da quantidade de energia elétrica necessária para atender aos consumidores em um período específico, utilizando dados históricos de consumo de eletricidade. Para isso, será aplicada a RNA PMC com entradas atrasadas no tempo ou *time delay neural network* (TDNN). As RNAs podem ser treinadas para identificar padrões de consumo e, posteriormente, realizar a previsão de demanda.

### 5.1. Previsão de Demanda de Energia Elétrica

A rede PMC com entradas atrasadas no tempo TDNN é adequada para o mapeamento de sistemas dinâmicos como previsão de cargas elétricas. Sua estrutura é enquadrada dentro da arquitetura *feedforward* de múltiplas camadas, onde não existe realimentação, e; portanto, o sinal de entrada propaga-se para frente camada a camada sem que exista realimentação das saídas dos neurônios de camadas posteriores em direção às camadas iniciais (SILVA; SPATTI; FLAUZINO, 2016).

Assim, a previsão de valores posteriores a partir de um instante de tempo, é avaliada em função do conhecimento de valores anteriores no tempo conforme (13).


$$H(t) = f\{H(t-1), H(t-2), \dots, H(t-n_p)\} \quad (13)$$

Onde  $n_p$  representa a quantidade de horas passadas (histórico de carga) aplicadas para estimação do valor  $H(t)$ , que corresponde a hora subsequente da atual. Na Figura 8, apresenta-se a topologia da rede PMC com entradas atrasadas no tempo.

Para estimação da demanda de eletricidade, os dados de cargas são divididos em intervalos de tempo para a criação de janelas de dados deslizantes. Cada janela representa um período contínuo de dados históricos, que compõem o conjunto de entradas da rede. Neste estudo, a janela de dados é composta por horas, onde se tem o valor de carga elétrica a cada hora.

A partir das  $N_p$  amostras que representam o histórico de consumo de energia, refletindo o comportamento ou padrão de consumo, pode-se obter  $H(t)$ , o valor previsto, levando em consideração as amostras passadas. Supondo que a saída desejada seja  $d(t)$ , durante o processo de treinamento a rede executará diversos processos iterativos cujo objetivo é ajustar as matrizes de pesos, buscando minimizar o erro  $E(t)$  calculado a partir da diferença entre  $d(t)$  (carga real para determinada hora) e  $H(t)$  (carga prevista pela RNA). Assim, o erro é calculado de acordo com (14).

Figura 8 – Estrutura da rede PMC com entradas atrasadas no tempo.



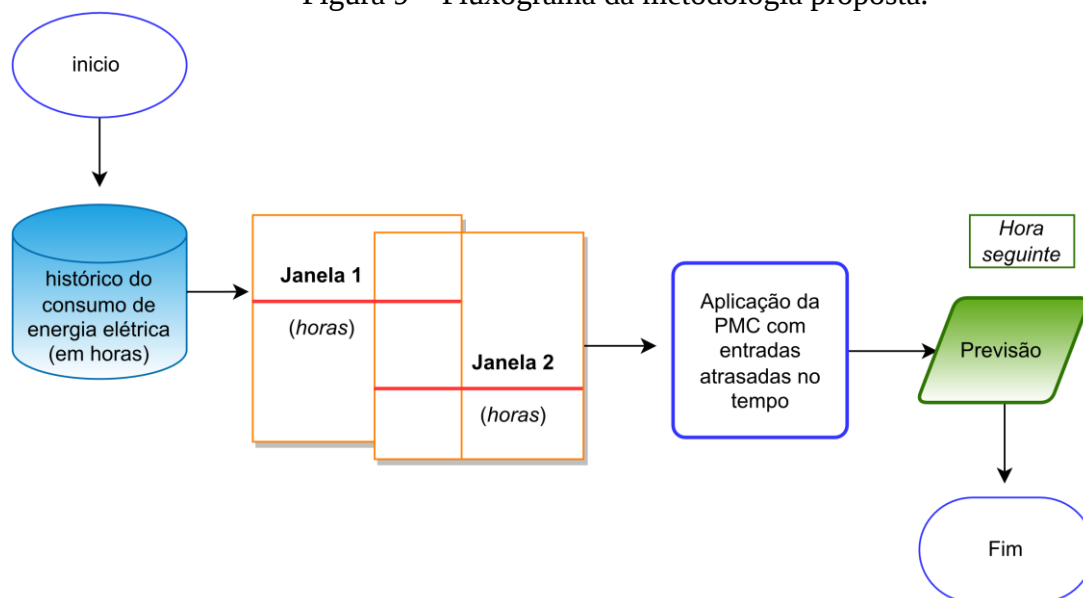
Fonte: Adaptado de Silva, Spatti e Flauzino (2016).

$$E(t) = H(t) - d(t), \quad \text{onde } (n_p + 1) \leq t \leq N \quad (14)$$

Sendo  $N$  a quantidade total de amostras do conjunto de dados.

A Figura 9 apresenta uma visão geral sobre o método proposto para previsão de cargas elétricas.

Figura 9 – Fluxograma da metodologia proposta.



Fonte: Elaboração da própria autora.

## 5.2. Análise do Desempenho do Sistema Previsor

O desempenho do sistema previsor é medido de acordo com o erro percentual médio absoluto ou *mean average percentage error* (MAPE).

$$MAPE = \frac{1}{N} \cdot \sum_{n=1}^N \left\{ \frac{d(t) - H(t)}{d(t)} \right\} \times 100 \quad (15)$$

Sendo  $d(t)$  o valor da carga real no instante  $t$ ,  $H(t)$  é o valor da carga prevista no instante  $t$ , e  $N$  é a quantidade total de amostras pertencentes ao conjunto de dados.

## 6. RESULTADOS

Neste trabalho aplica-se a RNA-PMC com entradas atrasadas no tempo para previsão de demanda de energia elétrica. A rede neural PMC foi treinada e validada no ambiente MATLAB.

### 6.1. Primeiro Estudo de Caso

#### 6.1.1. Descrição da Base de Dados

Este primeiro estudo de caso contém ao todo 96 amostras/horas para treinamento referentes a 4 dias sendo uma amostra representando o consumo em kWh a cada 1h e 24 amostras/horas para validação que corresponde a um dia (SILVA; SPATTI; FLAUZINO, 2016).


#### 6.1.2. Previsão de Cargas Elétricas

A rede PMC demandou 388 épocas para treinamento. A Figura 10 apresenta o erro quadrático médio (EQM) para cada época de treinamento.

A Figura 11 contém uma comparação gráfica entre a carga prevista pela rede PMC e a carga real.


Em último, todos os parâmetros da rede neural PMC adotados neste primeiro estudo de caso estão alocados na Tabela 1.

Figura 10 – Erro quadrático médio após cada época de treinamento da rede neural.



Fonte: Elaboração da própria autora.

Figura 11 – Carga real versus carga prevista para o primeiro estudo de caso.



Fonte: Elaboração da própria autora.

Tabela 1 – Parâmetros aplicados nas simulações do estudo de caso 1.

| Parâmetros                                    | Valores            |
|-----------------------------------------------|--------------------|
| Taxa de treinamento                           | $9 \times 10^{-1}$ |
| Precisão do treinamento                       | $1 \times 10^{-6}$ |
| Número de épocas para treinamento             | 388                |
| Inclinação da função de ativação – $\beta$    | 1,0                |
| Bias ou peso da entrada fixa                  | -1,0               |
| Topologia da rede neural                      | 10–15–1            |
| Número de amostras do conjunto de treinamento | 96 amostras (80%)  |
| Número de amostras do conjunto de teste       | 24 amostras (20%)  |
| MAPE                                          | 0,546%             |

Fonte: Elaboração da própria autora.

## 6.2. Segundo Estudo de Caso

### 6.2.1. Descrição da Base de Dados

Este segundo estudo de caso contém dados reais de 744 amostras que correspondem ao consumo em kWh de cada hora ao longo de 31 dias. Ao todo são 720 amostras/horas (30 dias) para treinamento da RNA-PMC e 24 amostras/horas referente a 1 dia para testar a RNA-PMC. As amostras de teste não participaram da etapa de treinamento da rede neural.

### 6.2.2. Codificação das Entradas da Rede Neural

Uma prática comum no estudo de Redes Neurais Artificiais (RNAs) envolve a codificação das entradas da rede para facilitar o processo de treinamento, melhorando assim a eficácia e a capacidade de aprendizado dela. Esse procedimento de codificação permite que a rede compreenda e processe informações de maneira mais eficiente, contribuindo para um treinamento mais eficaz e resultados mais precisos.

As Tabelas 2 e 3 mostram a codificação binária para os 7 (sete) dias da semana e para as 24 horas do dia. Para codificação dos dias da semana e das horas do dia são necessários 3 bits (alocados em 3 entradas da RNA) e 5 bits (alocados em 5 entradas da RNA), respectivamente.

### 6.2.3. Previsão da Demanda

A RNA-PMC foi treinada com algoritmo de aprendizagem retropropagação ou *backpropagation*. Utilizou-se *time delay neural network* (TDNN) para previsão da série temporal.

Ao contrário do primeiro estudo de caso, outras entradas são incorporadas para aumentar a taxa de acerto da RNA-PMC na previsão de cargas elétricas: os dias semana e as horas do dia.

O consumo de energia é influenciado pelas horas do dia e pelos dias da semana. Nos finais de semana, o consumo das unidades consumidoras (UCs) tende a aumentar, pois as pessoas permanecem mais tempo em suas casas. Por outro lado, após as 8h da manhã nos dias úteis, o consumo de energia tende a cair, pois as pessoas vão para o trabalho e/ou para a escola.

Desse modo, a RNA-PMC possui  $(8 + \text{comprimento do janelamento})$  entradas, sendo 5 entradas/bits para as horas do dia e 3 entradas/bits para os dias da semana.

A Figura 12 apresenta a comparação entre o consumo real em kWh das 24 amostras/horas de teste (curva em cor vermelha) com o consumo predito pela RNA-PMC (curva em cor azul). Todos os parâmetros adotados para a RNA-PMC constam na Tabela 4.

Ao analisar a Figura 12, percebe-se que a previsão do consumo de hora em hora se aproxima do consumo real com MAPE de 5,476%.

Tabela 2 – Codificação binária para os dias da semana.

| <b>Dias da Semana</b> | <b>Codificação Binária</b> |
|-----------------------|----------------------------|
| Domingo               | 001                        |
| Segunda-Feira         | 010                        |
| Terça-Feira           | 011                        |
| Quarta-Feira          | 100                        |
| Quinta-Feira          | 101                        |
| Sexta-Feira           | 110                        |
| Sábado                | 111                        |


Fonte: Elaboração da própria autora

Tabela 3 – Codificação binária para as horas do dia.

| <b>Horas do Dia</b> | <b>Codificação Binária</b> |
|---------------------|----------------------------|
| 0h                  | 00000                      |
| 1h                  | 00001                      |
| 2h                  | 00010                      |
| 3h                  | 00011                      |
| 4h                  | 00100                      |
| 5h                  | 00101                      |
| 6h                  | 00110                      |
| 7h                  | 00111                      |
| 8h                  | 01000                      |
| 9h                  | 01001                      |
| 10h                 | 01010                      |
| 11h                 | 01011                      |
| 12h                 | 01100                      |
| 13h                 | 01101                      |
| 14h                 | 01110                      |
| 15h                 | 01111                      |
| 16h                 | 10000                      |
| 17h                 | 10001                      |
| 18h                 | 10010                      |
| 19h                 | 10011                      |
| 20h                 | 10100                      |
| 21h                 | 10101                      |
| 22h                 | 10110                      |
| 23h                 | 10111                      |

Fonte: Elaboração da própria autora.

Figura 12 – Carga real versus carga prevista para o segundo estudo de caso.



Fonte: Elaboração da própria autora.

Tabela 4 – Parâmetros aplicados nas simulações para o segundo estudo de caso.

| Parâmetros                                    | Valores                               |
|-----------------------------------------------|---------------------------------------|
| Número de entradas da RNA-PMC                 | 11                                    |
| Janelamento TDNN                              | 3 bits                                |
| Topologia da rede neural                      | 11–20–1                               |
| Taxa de treinamento                           | $9 \times 10^{-1}$                    |
| Precisão do treinamento                       | $1 \times 10^{-6}$                    |
| Número de épocas para treinamento             | 138                                   |
| Inclinação da função de ativação – $\beta$    | 0,5                                   |
| Bias ou peso da entrada fixa                  | 1,0                                   |
| Número de amostras do conjunto de treinamento | 720 amostras/horas ou 30 dias (96,8%) |
| Número de amostras do conjunto de teste       | 24 amostras/horas ou 1 dia (3,2%)     |
| MAPE                                          | 5,476%                                |

Fonte: Elaboração da própria autora.

## 7. CONCLUSÕES

A rede neural artificial (RNA) *perceptron* multicamadas (PMC) ou *multilayer perceptron* consiste em uma rede neural muito flexível e adequada para uma série de problemas como: classificação, otimização de sistemas, predição de séries temporais, controle e outros.

Neste estudo a RNA-PMC foi aplicada para predição de séries temporais sendo conformadas por cargas elétricas em kWh. A RNA-PMC foi treinada com algoritmo de aprendizagem retropropagação ou *backpropagation* e utilizou-se *time delay neural network* (TDNN) para previsão da série temporais reais de cargas elétricas em kWh.

A RNA-PMC foi aplicada em 2 (dois) estudos de caso onde o consumo em kWh de cada hora do dia é conhecido. No primeiro estudo de caso a rede foi treinada com 4 dias (96 amostras/horas) e 1 dia (24 amostras/horas) foram aplicadas para teste. Por outro lado, no segundo estudo de caso, a rede foi treinada com 30 dias (720 amostras/horas) e 1 dia (24 amostras) foram aplicadas para teste. Nos dois estudos de caso a RNA-PMC obteve êxito na predição de séries temporais com MAPE de 0,546% e de 5,476%, respectivamente.

## 8. REFERÊNCIAS

BRANGIONI, G. B. **Análise e Previsão de Carga Elétrica via Redes Neurais Convolucionais**. 2023. 40f. Monografia (Graduação em Engenharia de Controle e Automação), Universidade Federal de Ouro Preto, Ouro Preto, Minas Gerais, 2023.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA – CCEE. **Consumo de Energia no Brasil Cresceu 1,4% no Primeiro Semestre de 2023, aponta CCEE** Disponível em: <<https://www.ccee.org.br/pt/web/guest/-/consumo-de-energia-no-brasil-cresceu-1-4-no-primeiro-semester-de-2023-aponta-ccee>>. Acesso em: 01 nov. 2023.

FERREIRA, A. B. A. **Previsão de Carga Multinodal Utilizando Rede Neural ARTMAP Euclidiana**. 2020. 76f. Dissertação de Mestrado (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, 2020.

GARCIA, L. M. D. **Avaliação de Métodos de Previsão de Cargas Elétricas em Curto Prazo para Aplicação em Sistemas de Distribuição Inteligentes**. 2013. 85f. Dissertação de Mestrado (Mestrado em Engenharia Elétrica) – Centro de Estudos em Energia e Sistemas de Potência (CEESP), Universidade Federal de Santa Maria (UFSM), Santa Maria, RS, 2013.

GOMES, T. T. **Rede ARTMAP Euclidiana Utilizada na Solução do Problema de Previsão de Cargas Elétricas**. 2017. 75f. Dissertação de Mestrado (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, 2017.

GUELFÍ, M. A., DECANINI, J. G. M. S. **Previsão de Carga Elétrica do Subsistema Sudeste/Centro-Oeste do Sistema Interligado Nacional Utilizando Redes Neurais Artificiais**. *Revista Sinergia*, v. 24, n. 1, p. 32–50, 2023.

LOPES, M. L. M. **Desenvolvimento de Redes Neurais para Previsão de Cargas Elétrica de Sistemas de Energia Elétrica**. 2005. 169f. Tese de Doutorado (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, 2005.

MACHADO, L. M. G. **Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo Considerando a Inserção de Micro e Minigeração Fotovoltaica**. 2005. 63f. Monografia (Graduação em Engenharia Elétrica), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

MELO, J. D. **Aplicações de Sistemas Multiagentes na Previsão Espacial de Demanda Elétrica em Sistemas de Distribuição**. 2010. 152f. Dissertação de Mestrado (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, 2010.

MENEZES, M. L.; CASSIANO, K. M.; SOUZA, R. M.; JÚNIOR, L. A. T.; PESSANHA, J. F. M.; SOUZA, R. C. Modelagem e Previsão de Demanda de Energia com Filtragem SSA. **Revista da Estatística**, v. 3, n. 2, p. 170–187, 2014.

MINUSSI, C. R.; LOTUFO, A. D. P. **Redes Neurais: Introdução e Princípios Conceitos**. Disponível em: <[https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/apostila-redes-neurais-anna-diva\\_minussi.pdf](https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/apostila-redes-neurais-anna-diva_minussi.pdf)>. Acesso em: 01 nov. 2023.

MORAIS, L. B. S. **Previsão de Carga de Curto Prazo Utilizando Redes Neurais Artificiais**. 2022. 64f. Dissertação de Mestrado (Mestrado em Engenharia Elétrica), Universidade Federal de Itajubá, Itajubá, Minas Gerais, 2022.

NOGUEIRA, L. C.; SALGADO, R. M. **Comparação de Estratégias de Previsão de Carga Elétrica Utilizando Support Vector Machine**. 2013. 13f. Monografia (Graduação em Ciências da Computação), Universidade Federal de Alfenas, Alfenas, Minas Gerais, 2013.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Representations by Back-Propagating Error. **Nature**, v. 323, p. 533-536, 1986.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos**. São Paulo: Ed. ARTLIBER, 2016, 431 p.