

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

MATTHEUS CORPOLATO

**TÉCNICAS DE REDES NEURAS ARTIFICIAIS APLICADAS NA PREVISÃO DE
GERAÇÃO DE UMA USINA FOTOVOLTAICA**

**TOLEDO
2022**

MATTHEUS CORPOLATO

**TÉCNICAS DE REDES NEURAS ARTIFICIAIS APLICADAS NA PREVISÃO DE
GERAÇÃO DE UMA USINA FOTOVOLTAICA**

**ARTIFICIAL NEURAL NETWORK TECHNIQUES APPLIED IN THE GENERATION
FORECAST OF A PHOTOVOLTAIC PLANT**

Trabalho de conclusão de curso de graduação
apresentado como requisito para obtenção do título de
Bacharel em Engenharia Eletrônica da Universidade
Tecnológica Federal do Paraná (UTFPR).

Orientadora: Sofia Moreira de Andrade Lopes.

Coorientador: Felipe Walter Dafico Pfrimer.

**TOLEDO
2022**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

MATTHEUS CORPOLATO

**TÉCNICAS DE REDES NEURAS ARTIFICIAIS APLICADAS NA PREVISÃO DE
GERAÇÃO DE UMA USINA FOTOVOLTAICA**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título de
Bacharel Engenharia Eletrônica da Universidade
Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 28 de novembro de 2022.

Prof. Sofia Moreira de Andrade Lopes
(Orientador)
Escola de Engenharia de São Carlos – EESC/USP

Prof. Dr. Felipe Walter Dafico Pfrimer
(Coorientador)
Universidade Tecnológica Federal do Paraná - UTFPR

Prof. Dr. Marcos Roberto Bombacini
Universidade Tecnológica Federal do Paraná – UTFPR

Eng. Victor Hideki Yoshizumi
Escola de Engenharia de São Carlos – EESC/USP

**TOLEDO
2022**

RESUMO

A inserção de sistemas fotovoltaicos (FV) nas redes de distribuição de energia elétrica, por meio da geração distribuída é promissora, pois garante maior disponibilidade de energia elétrica ao sistema de distribuição. Entretanto, por ser uma fonte de energia com característica intermitente, limitado pelas variações climáticas, a disseminação desses sistemas em larga escala pode gerar instabilidades na rede. Com objetivo de prever a potência de saída destes sistemas FV, foram desenvolvidos algoritmos destinados à previsão de geração de energia. Obter uma previsão com exatidão pode contribuir para estabilizar e proteger a operação da rede, além de possibilitar a inserção da energia fotovoltaica em grande escala. Este trabalho tem como objetivo empregar técnicas de Redes Neurais Artificiais (RNAs) como ferramentas de previsão de geração de energia fotovoltaica. Como diferencial, foi utilizada uma Rede Perceptron Multicamadas (PMC) combinada a uma classificação preliminar dos dados de entrada, que validou a hipótese de que essa classificação prévia apresenta influência positiva nos resultados da RNA.

Palavras-chave: redes neurais artificiais; rede perceptron multicamadas; pré-classificação de dados; energia fotovoltaica.

ABSTRACT

The insertion of photovoltaic (PV) systems in electricity distribution networks, through distributed generation, is promising, as it guarantees greater availability of electricity to the distribution system. However, as it is an energy source with these intermittent characteristics, limited by climatic variations, the dissemination of large-scale systems can generate instabilities in the network. In order to predict the output power of these PV systems, research related to energy generation prediction methods was developed. Obtaining an accurate forecast can help to stabilize and protect the operation of the grid, in addition to enabling the insertion of photovoltaic energy on a large scale. This work aims to present techniques of Artificial Neural Networks (ANN) as tools for predicting photovoltaic energy generation. As a differential, a Multilayer Perceptron Network (PMC) was used combined with a preliminary classification of the input data, which validated the hypothesis that this previous classification has an influence on the ANN results.

Keywords: artificial neural networks; multilayer perceptron network; data pre-classification; photovoltaic energy.

LISTA DE ILUSTRAÇÕES

Figura 1 - Efeito fotovoltaico	19
Figura 2 - Estrutura do neurônio biológico.....	22
Figura 3 - Estrutura generalizada de um neurônio artificial.	23
Figura 4 - Representação genérica da rede PMC.	25
Figura 5 - Representação processo treinamento da rede PMC.....	25
Figura 6 - Ambiente da ferramenta nstart.	27
Figura 7 - Ambiente da ferramenta ntstool.	28
Figura 8 - Ambiente de importação de dados e treinamento da RNA.	28
Figura 9 - Série temporal da geração de energia elétrica diária.....	29
Figura 10 - Potência de saída do dia 27/12/2022 representado de duas formas diferentes.	30
Figura 11 - Série temporal para cada estação climática.	34
Figura 12 - Domínios de normalização para a função de ativação tangente hiperbólica.	35
Figura 13 - Conversão de segmentos proporcionais.....	35
Figura 14 – Dias típicos por estação	37
Figura 15 - Decomposição da série temporal de inverno.	37
Figura 16 - Decomposição da série temporal de primavera.	38
Figura 17 - Decomposição da série temporal de outono.	38
Figura 18 - Decomposição da série temporal de verão.....	39
Figura 19 - Fluxograma do tratamento realizado nos dados.....	40
Figura 20 - Fluxograma da validação experimental.	41
Figura 21 - Resultado da previsão da rede MPL para série de inverno.....	45
Figura 22 - Recorte do resultado da previsão da rede MPL para série de inverno.	45
Figura 23 - Histograma de resíduos série temporal de inverno.	46
Figura 24 - Função autocorrelação dos erros de previsão da série temporal de inverno.	46
Figura 25 - Resultado da previsão da rede MPL para série de primavera.....	48
Figura 26 - Recorte do resultado da previsão da rede MPL para série de primavera.	48
Figura 27 - Histograma de resíduos série temporal de primavera.....	49
Figura 28 - Função autocorrelação dos erros de previsão da série temporal de primavera.	49
Figura 29 - Resultado da previsão da rede MPL para série de verão.	51
Figura 30 - Recorte do resultado da previsão da rede MPL para série de verão.	51
Figura 31 - Histograma de resíduos série temporal de verão.	52
Figura 32 - Função autocorrelação dos erros de previsão da série temporal de verão.....	52
Figura 33 - Resultado da previsão da rede MPL para série de outono.....	54
Figura 34 - Recorte do resultado da previsão da rede MPL para série de outono.	54
Figura 35 - Histograma de resíduos série temporal de outono.....	55
Figura 36 - Função autocorrelação dos erros de previsão da série temporal de outono.	55

Figura 37 - Resultado da previsão da rede MPL para série sem classificação preliminar.....	57
Figura 38 - - Recorte do resultado da previsão da rede MPL para série sem classificação preliminar.....	57
Figura 39 - Histograma de resíduos série temporal de sem classificação preliminar.....	58
Figura 40 - Função autocorrelação dos erros de previsão da série temporal sem classificação preliminar.....	58
Figura 41 - Verificação de <i>overfitting</i> série de inverno.....	60

LISTA DE TABELAS

Tabela 1 – Alteração do período de amostragem.....	33
Tabela 2 - Datas de início e fim das estações climáticas.....	33
Tabela 3 - Quantidade de amostras por série temporal.....	34
Tabela 4 – Resultados (MSE) de treinamento e teste da série temporal de inverno.	44
Tabela 5 - Resultados de treinamento e teste da série temporal de primavera.	47
Tabela 6 - Resultados de treinamento e teste da série temporal de verão.	50
Tabela 7 - Resultados de treinamento e teste da série temporal de outono.....	53
Tabela 8 - Resultados de treinamento e teste da série temporal sem classificação preliminar.....	56
Tabela 9 - Resumo dos melhores resultados das previsões.....	59

LISTA DE ABREVIATURAS E SIGLAS

ANEEL – Agência Nacional de Energia Elétrica

ANN – Artificial neural networks

BP – Backpropagation

FV – Fotovoltaica

LM – Levenberg-Marquardt

MG – Memória Gama

MLP – Multilayer Perceptron

PMC – *Perceptron* de Multicamadas

RBF – Radial Basis Function Neural Network

RMR – Rede Neural Recursiva

RNA – Rede Neural Artificial

UTFPR - Universidade Tecnológica Federal do Paraná

SUMÁRIO

1.	INTRODUÇÃO	13
1.1	Contextualização	13
1.2	Motivação da pesquisa	14
1.3	Objetivo da pesquisa	16
1.4	Estrutura do trabalho	17
2.	REVISÃO DE LITERATURA	18
2.1	Energia solar.....	18
2.1.1	Efeito fotovoltaico	18
2.1.2	Funcionamento da célula fotovoltaica	19
2.1.3	Estudos sobre previsão de energia elétrica fotovoltaica.....	20
2.2	Redes Neurais Artificiais	21
2.2.1	Neurônio biológico.....	22
2.2.2	Neurônio Artificial	22
2.2.3	Funções de ativação de redes neurais.....	23
2.2.4	Arquitetura de RNA	23
2.2.5	Processo de treinamento de RNA	24
2.2.6	Rede Perceptron multicamadas	24
2.3	O Software MATLAB	26
2.3.1	A Toolbox nnstart	27
3.	CARACTERÍSTICAS DA SÉRIE TEMPORAL	29
3.1	Aquisição dos dados	29
3.2	Pré-processamento dos dados	31
3.3	Classificação preliminar dos dados	33
3.4	Processamento dos dados.....	35
3.5	Decomposição dos dados	36
3.6	Fluxograma do processamento dos dados	40
4.	IMPLEMENTAÇÃO DO MÉTODO DE PREVISÃO PROPOSTO	41
4.1	Fluxograma da validão experimental.....	41
4.2	Definição dos parâmetros de desempenho utilizados.....	41
4.2.1	Análise do erro	42
4.2.2	Análise de resíduos	42
4.2.3	Overfitting	42
5.	RESULTADOS E DISCUSSÕES	44

5.1	Previsão da série temporal de inverno.....	44
5.2	Previsão da série temporal de primavera.....	47
5.3	Previsão da série temporal de verão	50
5.4	Previsão da série temporal de outono.....	53
5.5	Previsão da série temporal sem classificação preliminar	56
5.6	Diagnóstico dos resultados	59
5.7	Contribuições para o campus	61
6.	CONCLUSÕES	62

1. INTRODUÇÃO

1.1 Contextualização

O crescimento populacional causou elevação vertiginosa na demanda energética mundial. Para suprir essa demanda, por muito tempo foram utilizadas fontes de energia tradicionais, baseadas na queima de combustíveis fósseis, responsáveis pela emissão de gases ligados ao efeito estufa, que por sua vez alteram as condições climáticas. Com o objetivo de mitigar este problema, muitos projetos e pesquisas vêm sendo realizados em busca de implementações economicamente viáveis para produção de energias renováveis (PHILIPPI; BELICO, 2016).

Diante de tal preocupação, em 2015 vários países se reuniram e assinaram o chamado “Acordo de Paris”, cujo objetivo central é manter o aumento da temperatura até o final do século XXII abaixo de 2 °C acima dos níveis pré-industriais e ainda fazer esforços para limitar o aumento da temperatura a 1,5 °C reconhecendo que isso reduziria significativamente os riscos e impactos das mudanças climáticas (UNFCCC, 2018).

Para que houvesse a redução da emissão de gases de efeito estufa, fontes de energia alternativas passaram a ser cada vez mais necessárias. Nas últimas duas décadas, houve um enorme aumento na compreensão do princípio operacional de dispositivos fotovoltaicos, o que levou a um rápido aumento na eficiência de conversão de energia de tais dispositivos (BHATTACHARYA; CHAKRABORTY; PAL, 2014).

De acordo com o Boletim de Monitoramento do Sistema Elétrico divulgado em fevereiro de 2022, houve uma evolução da capacidade instalada de geração de energia elétrica fotovoltaica de 70,2% entre os períodos de fevereiro de 2021 a fevereiro de 2022. Dada essa elevação de instalação de sistemas fotovoltaicos, o Brasil detém aproximadamente 7,3% da capacidade instalada proveniente de fontes solares, correspondendo a 14.004 MW (MINISTÉRIO DE MINAS E ENERGIA, 2022).

As centrais fotovoltaicas podem apresentar diferentes dimensões, desde uma mini central destinada ao consumo residencial, médias ou de grande porte, destinado a comercialização da energia. A comercialização ocorre pelo conceito de geração distribuída, podendo ser definida como uma fonte de energia elétrica conectada diretamente à rede de distribuição ou situada no próprio consumidor (ACKERMAN; et al, 2001).

A comercialização de energia gerada pelas micro e mini centrais fotovoltaicas é regulamentada pela Resolução Normativa nº482/2012 pela Agência Nacional de Energia Elétrica. Essa resolução permitiu que os consumidores que geram sua própria energia, entreguem o excedente ao sistema elétrico da rede pública de distribuição, estes excedentes são transformados em créditos que poderão ser compensados em outro momento na conta de energia (ANEEL, 2012).

Apesar de contribuir com maior disponibilidade de energia e adiamento de investimentos em expansão dos sistemas de transmissão e distribuição, os sistemas fotovoltaicos podem causar perturbações à rede de distribuição. Devido à sua natureza intermitente, as centrais fotovoltaicas se comportam como carga-fonte e nos períodos de indisponibilidade (à noite ou em condições de sombreamento) deixam de se comportar como fonte. Essa condição bidirecional requer atenção para o controle de tensão e reativos, além de exigir que o sistema de distribuição seja capaz de atender a cargas, mesmo na ausência dessas fontes geradoras fotovoltaicas (VIAN ÂNGELO; et al, 2021).

Diante deste problema, uma estimativa de geração de energia dos sistemas intermitentes se torna importante na gestão e planejamento de sua distribuição, proporcionando ao sistema qualidade e melhor desempenho. Uma ferramenta para realizar estas previsões são as redes neurais artificiais, que tem capacidade de estimar valores futuros, levando em consideração valores passados, através de previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2019).

1.2 Motivação da pesquisa

A inserção em larga escala de geradores fotovoltaicos pode ocasionar problemas em sistemas elétricos de potência, principalmente em redes de distribuição, transmissão e geração de energia. Partindo do pressuposto que esse tipo de gerador está instalado principalmente nos telhados de edificações em centros urbanos, devido a sua concentração, uma desconexão repentina em grande proporção deixa o sistema elétrico suscetível a instabilidades (TAN, 2004).

Essa desconexão repentina pode acontecer devido a ocorrência de falhas ocasionadas pelo próprio sistema de proteção integrado ao sistema fotovoltaico, que desconectam as unidades geradoras da rede em caso de alguma perturbação no controlador ou inversor. Adicionalmente, a desconexão repentina pode acontecer em

decorrência de condições meteorológicas que afetem a irradiância da área e também podem causar distúrbios ao sistema (TAN, 2004).

Esses distúrbios na rede elétrica podem gerar problemas de flutuações de potência e tensão no ponto de conexão com a rede, má qualidade de energia, tais como o aumento da presença de harmônicos na tensão e na corrente, em casos raros, variações na frequência da rede (BERQUÓ; SOUZA; FRANÇA, 2018).

Diante disso, fica evidente que a desconexão repentina destes geradores FV pode gerar instabilidades em todo o sistema elétrico. Realizar uma previsão precisa dessas fontes intermitentes é importante para estabilizar e proteger a operação da rede, além de promover a inserção da energia fotovoltaica em grande escala (DAS et al., 2018).

Existem três abordagens para previsão de energia solar. Um método é por meio do uso de equações analíticas que tem como objetivo modelar a irradiância incidida no sistema, outra abordagem é através de métodos estatísticos e aprendizado de máquina que tem como objetivo prever diretamente a potência de saída do sistema. A terceira abordagem consiste na mistura de ambos os métodos citados, essa mistura se chama de modelo híbrido (ANTONANZAS et al., 2016).

Os trabalhos desenvolvidos por Chen et al., (2011) propuseram uma metodologia utilizando métodos estatísticos, onde utilizaram redes neurais artificiais de função de base radial (RBF) para realizar a previsão de geração de energia FV 24 horas a frente. Nesta metodologia, os parâmetros de entrada como irradiância solar, umidade relativa e temperatura ambiente do sistema sofrem uma classificação preliminar em dias ensolarados, nublados e chuvosos. Após aplicado os testes, foi validado que o método com classificação preliminar do tipo de clima é superior ao método sem classificação.

A metodologia de classificação preliminar também foi validada por Shi et al., (2012) que combinou técnicas de máquinas de vetor de suporte (MVS) e classificação preliminar de dados para prever a geração de um sistema FV. A classificação dos parâmetros de entrada foi dividida em quatro tipo de condições climáticas, sendo elas nublado, nevoeiro, ensolarado e chuvoso.

Em seus trabalhos, Shuai et al., (2017) implementou um algoritmo de agrupamento KNN (K-ésimo vizinho mais próximo) que dividiu os dias em ensolarados, nublados, chuvosos e muito nublados. Essa técnica de agrupamento

combinada com o modelo de previsão com base na Cadeia de Markov funcionou de forma eficaz para prever a saída da rede fotovoltaica analisada.

No capítulo 2, serão discutidos mais estudos que aplicaram diferentes métodos para prever a potência de saída de unidades FV, bem como os métodos e ferramentas utilizadas. Diante dos estudos abordados nesta seção, observa-se que as estratégias que utilizaram uma classificação preliminar dos dados apresentaram vantagem sobre as que não aplicaram tal classificação, por este motivo, o presente trabalho irá explorar a técnica de classificação preliminar dos dados de entrada da RNA.

1.3 Objetivo da pesquisa

Este trabalho tem como objetivo principal a aplicação de um modelo computacional baseado em redes neurais artificiais para realizar a previsão de geração de energia fotovoltaica, combinado a uma classificação preliminar dos dados.

Os dados utilizados na pesquisa são dados reais coletados de um sistema fotovoltaico em funcionamento na Universidade Tecnológica Federal do Paraná e a validação da metodologia será dada pela análise de que a previsão da série temporal, combinada à uma classificação preliminar dos dados de entrada, a classificação preliminar deve apresentar menor erro em relação à previsão sem classificação preliminar dos dados.

Com base no objetivo principal, destacam-se alguns objetivos específicos, tais como:

- Justificar o problema da previsão de geração de energia fotovoltaica;
- Realizar uma revisão dos principais estudos de previsão de geração fotovoltaica;
- Fazer a classificação dos dados coletados na unidade fotovoltaica de acordo com as estações climáticas;
- Desenvolver um modelo de previsão de geração fotovoltaica utilizando o *software* MATLAB;
- Aplicar os dados classificados no modelo de previsão desenvolvido;
- Aplicar os dados sem classificação no modelo de previsão desenvolvido;
- Realizar a análise comparativa dos resultados com e sem classificação para validação da metodologia.

1.4 Estrutura do trabalho

Este trabalho é dividido em cinco capítulos, partindo da introdução como capítulo 1.

Capítulo 2 – Revisão de literatura: neste capítulo será apresentado uma breve abordagem sobre energia solar, efeito fotovoltaico, funcionamento da célula fotovoltaica, estudos de previsão de geração fotovoltaica utilizando redes neurais artificiais, funcionamento das redes neurais artificiais (RNA) e a *toolbox nnstart* do ambiente MATLAB.

Capítulo 3 – Características da série temporal: neste capítulo será descrito todas as características da série temporal pertinente para este trabalho, como a aquisição, pré-processamento e decomposição dos dados. Além disso, também será explicado a metodologia proposta, a técnica aplicada na classificação dos dados, a estrutura da rede neural, algoritmo de treinamento e o *software* que será utilizado.

Capítulo 4 – Implementação do método de previsão proposto: neste capítulo será abordado o fluxograma de implementação da metodologia proposta e parâmetros de desempenho para avaliação dos resultados.

Capítulo 5 - Resultados e discussões: neste capítulo serão apresentados e analisados os resultados obtidos com base na metodologia desenvolvida neste trabalho.

Capítulo 6 - Conclusões: neste capítulo serão apresentados os resultados alcançados com base no trabalho desenvolvido.

2. REVISÃO DE LITERATURA

Neste capítulo aborda-se os principais conceitos relacionados ao funcionamento de sistemas fotovoltaicos e em sequência os conceitos de redes neurais artificiais utilizados para estimação de geração de energia elétrica fotovoltaica.

2.1 Energia solar

Para entendimento de um sistema fotovoltaico é importante compreender alguns conceitos, tais como o de energia solar. A energia do sol é transmitida através do espaço na forma de radiação eletromagnética. Uma grandeza que quantifica a radiação solar é a irradiância, expressa na unidade de W/m^2 (watt por metro quadrado), que se trata de uma unidade de potência por área.

A irradiância é uma grandeza que pode ser facilmente medida, e na superfície terrestre a irradiância do sol é em torno de $1000 W/m^2$, esta é uma boa referência para avaliação da eficiência de células fotovoltaicas (VILLALVA; GAZOLI, 2012).

2.1.1 Efeito fotovoltaico

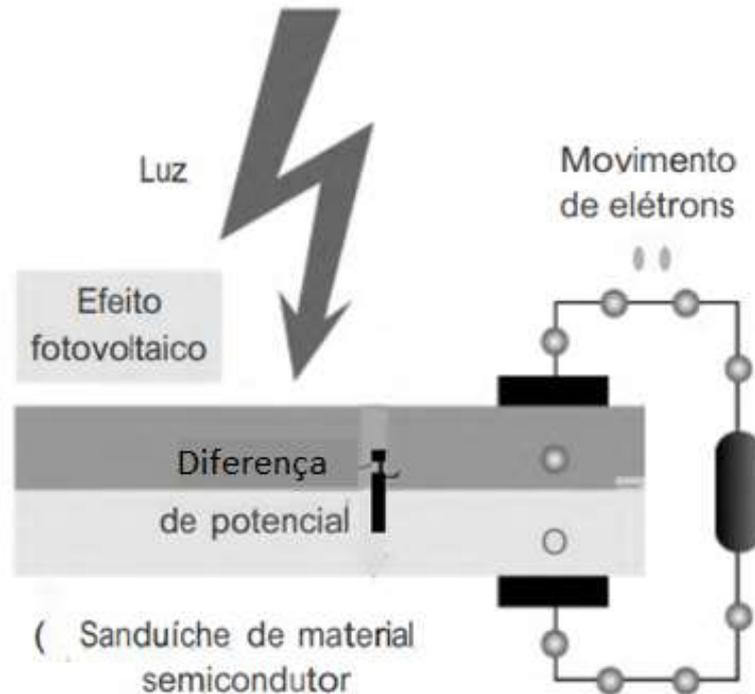
As primeiras descobertas que contribuíram para o desenvolvimento da energia fotovoltaica começaram em 1839, onde o cientista Alexandre-Edmond Becquerel observou que ao colocar duas placas de latão em um líquido condutor, disparava uma luz entre as placas, essa luz era na verdade corrente elétrica, que ficou conhecido como efeito fotovoltaico (BALFOUR; SHAW; NASH, 2019).

Outro avanço para a energia fotovoltaica aconteceu em 1950, com a descoberta por cientistas que o silício, segundo elemento mais abundante da terra, se torna responsivo a luz quando tratado com impurezas. Observou-se que quando a luz solar atinge um material semicondutor tratado, os elétrons presentes na estrutura dos átomos se desprendem e migram para a parte da célula do material tratado com ausência de elétrons, e partir desse fenômeno foi possível criar eletricidade com o auxílio de um circuito elétrico (BALFOUR; SHAW; NASH, 2019).

O efeito fotovoltaico pode ser melhor compreendido a partir da Figura 1, onde a radiação eletromagnética do Sol, quando incidida em determinados materiais, podem produzir tensões e correntes elétricas. Se a célula for conectada a dois terminais eletrodos, cria-se uma diferença de potencial entre eles. Se existir um

caminho elétrico entre esses dois terminais, irá surgir então, uma corrente elétrica (VILLALVA; GAZOLI, 2012).

Figura 1 - Efeito fotovoltaico



Fonte: Adaptado de Villalva e Gazoli (2012, p.41).

2.1.2 Funcionamento da célula fotovoltaica

Uma célula fotovoltaica é composta tipicamente de duas camadas de material semicondutor, geralmente feitas de silício, uma camada do tipo P e outra N. Embora existam células com múltiplas junções e maior número de camadas, seu funcionamento é bem semelhante. Segundo Villalva e Gazoli (2012) as células de múltiplas junções produzem mais energia, porém são mais caras e não tão populares como as de duas camadas.

O funcionamento dessa junção semicondutora se dá pela dopagem dos materiais, o material N possui maior quantidade de elétrons e o material P apresenta lacuna de elétrons. Devido essa diferença de concentração nas duas camadas, na presença de radiação solar os elétrons da camada N se transportam a fim de preencher as lacunas da camada P. Esses elétrons em movimento são coletados por eletrodos que fecham um circuito, formando uma corrente elétrica.

2.1.3 Estudos sobre previsão de energia elétrica fotovoltaica

Segundo Antonanzas et al., (2016) a variabilidade do recurso solar implica em dificuldades no gerenciamento da rede elétrica. Desta forma, realizar uma previsão precisa da geração de energia elétrica a partir deste recurso proporciona uma estabilidade para a rede. Essas previsões podem ser a partir de equações analíticas, aprendizagem homem-máquina ou uma mistura de ambos.

Existem muitos trabalhos cujo tema principal é realizar a previsão de geração de energia FV, estes trabalhos se diferem nos parâmetros de entrada, tipo de modelos, horizontes de previsão (curto, médio ou longo-prazo) e metodologia empregada. Um método muito conhecido de aprendizagem homem-máquina é o recurso de redes neurais artificiais.

A RNA utilizada para previsão de geração de energia FV é comumente alimentada por parâmetros físicos previamente correlacionados com a produção de energia, e tem como parâmetro de saída a potência gerada pelo sistema. Ogligari et al. (2013) utilizaram como parâmetros de entrada em seus trabalhos as grandezas físicas como temperatura ambiente, pressão atmosférica, velocidade do vento, umidade e porcentagem de nuvens cobrindo o céu.

Em seus trabalhos Lo Brano, Ciulla, Di Falco (2014) testaram diferentes arquiteturas de RNA para prever a energia elétrica gerada por um módulo fotovoltaico em condições reais, na avaliação de desempenho as RNAs apresentaram um erro dentro do intervalo de 0,05-1% em relação a potência de pico do módulo. Também se notou que as arquiteturas mais simples exigiam um tempo de treinamento mais longo, enquanto as mais robustas apresentavam um tempo de treinamento menor.

De Giogi, Congedo e Malvoni, (2014) implementou uma rede PMC e avaliou a saída para três diferentes vetores de entrada, os vetores foram alimentados por variáveis de potência, temperatura do módulo, temperatura ambiente, temperatura do modulo e a irradiância solar em dois diferentes ângulos de inclinação. O primeiro vetor foi composto apenas pela série temporal de potência, o segundo utilizou a série temporal de potência combinada aos dados de irradiância e o terceiro utilizou todas as variáveis combinadas.

No trabalho anterior, foi observado que o vetor que incluiu todas os parâmetros obteve melhor desempenho, ou seja, o erro quadrático médio normalizado

menor. Entretanto observou-se que o segundo vetor apresentou a mesma tendência quando os horizontes de tempo aumentam.

Portanto, considerando o desempenho satisfatório dos trabalhos presentes na literatura, este trabalho tem o objetivo de aplicar técnicas de previsão de séries temporais utilizando RNA. Neste caso, será implementado a arquitetura PMC, que apresenta vantagem sobre RNAs simples, e também técnicas de classificação preliminar de dados.

2.2 Redes Neurais Artificiais

Uma rede neural artificial é formada por um conjunto de unidades básicas de processamento que se comunicam enviando informações uma para a outra por meio de determinadas conexões que se inspiram no sistema nervoso dos seres vivos. A primeira publicação relacionada à neuro computação foi um artigo elaborado por McCulloch e Pitts (1943). Neste trabalho foi implementado o primeiro modelamento matemático baseado no neurônio biológico, inspirando o primeiro conceito de neurônio artificial (SILVA; SPATTI; FLAUZINO, 2019).

Segundo Flauzino (2019), em 1949 o primeiro método de treinamento para redes neurais proposto denominou-se de regra de aprendizado de Hebb, sendo essa baseada em hipóteses e observações de caráter neurofisiológico. Por volta de 1958, Frank Rosenblatt desenvolveu o primeiro computador idealizando o modelo básico *Perceptron*, que chamou atenção devido à capacidade em reconhecer padrões simples.

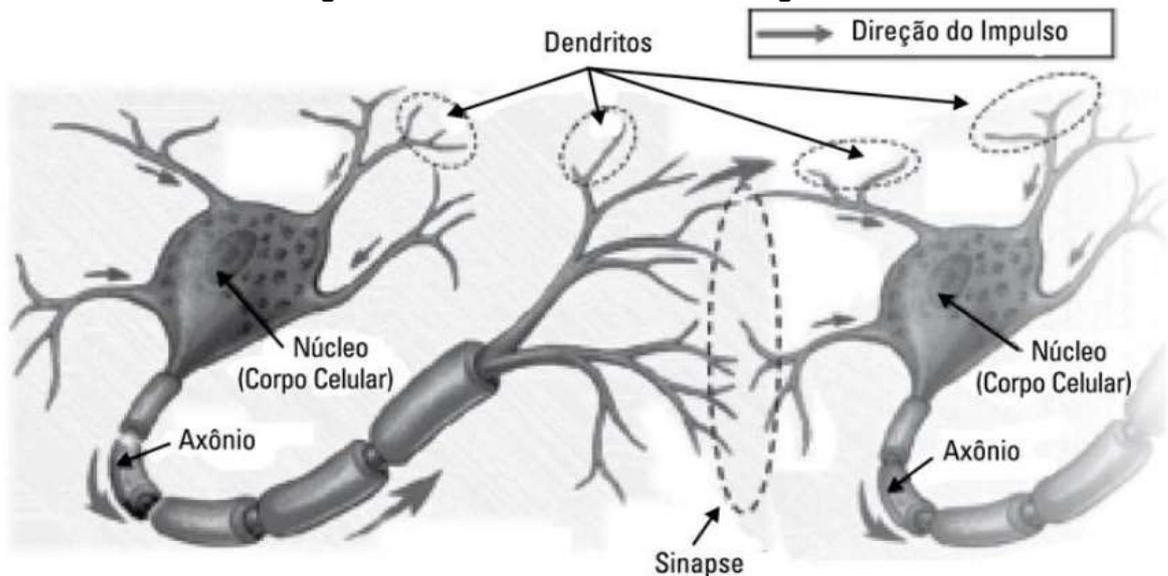
Atualmente, as RNAs são utilizadas em diversas áreas de conhecimento, tais como engenharia, medicina, economia, entre outras. Nestas áreas, as RNAs são aplicadas em diferentes contextos, sendo utilizadas para reconhecimento e classificação de padrões, controle de processos, aproximação de funções, otimização de sistemas e sistemas de previsão (SILVA; SPATTI; FLAUZINO, 2019). Neste trabalho será utilizado as RNAs aplicadas a sistemas de previsão, cujo objetivo consiste em estimar valores futuros de um processo levando-se em consideração dados passados.

2.2.1 Neurônio biológico

O neurônio é a célula elementar do sistema nervoso cerebral, cuja função é de conduzir impulsos (estímulos elétricos advindos de reações físico-químicas). Os estímulos entram nos neurônios através das sinapses que se conectam aos dendritos (ramificações de entrada de um neurônio conforme Figura 2 com axônios de outros neurônios).

As sinapses regulam as quantidades de informações que passam dos dendritos para célula nervosa correspondente. As informações são passadas para o somador (corpo celular), que as adiciona e as aplica um discriminador, onde se determina o nível mínimo de entrada acima do qual o neurônio dispara uma carga elétrica como resposta a um ou mais estímulos (LIMA; PINHEIRO; SANTOS, 2014).

Figura 2 - Estrutura do neurônio biológico.



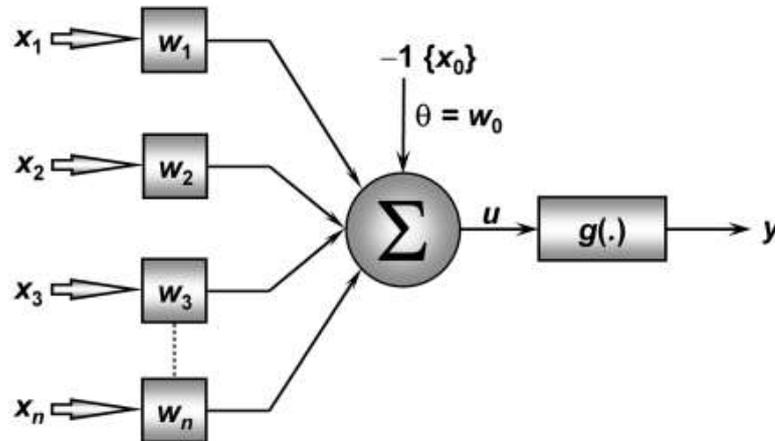
Fonte: Lima, Pinheiro e Santos (2014).

2.2.2 Neurônio Artificial

Os neurônios artificiais são modelos bem simplificados dos neurônios biológicos, inspirados a partir da análise da geração e propagação de impulsos elétricos da membrana celular dos neurônios. Um neurônio artificial pode ser implementado conforme Figura 3, onde: sinais de entrada vindos do meio externo (X_1, X_2, \dots, X_n) são ponderados pelos pesos sinápticos (W_1, W_2, \dots, W_n) que determinam a relevância de cada entrada. Esses sinais passam por um operador (Σ) que soma esses sinais ponderados. Desses valores somados é subtraído um limiar de ativação (θ), essa diferença determina um potencial de ativação (u), esse potencial que é

aplicado a função de ativação ($g(u)$) responsável por limitar o sinal de saída do neurônio (HAYKIN, 2000).

Figura 3 - Estrutura generalizada de um neurônio artificial.



Fonte: Flauzino et al., (2019).

Matematicamente pode-se expressar o modelo de neurônio da figura 3 através da equação 1:

$$u = \sum_{i=1}^n W_i \cdot X_i - \theta$$

$$y = g(u)$$
(1)

2.2.3 Funções de ativação de redes neurais

As funções de ativação podem ser divididas em dois grupos principais, funções totalmente diferenciáveis e parcialmente diferenciáveis. Seu papel é limitar amplitude de saída de um neurônio dentro de um intervalo de valores pré-determinados. Tipicamente o intervalo normalizado da amplitude de saída de um neurônio é dado pelo intervalo fechado $[0, 1]$ ou $[-1, 1]$ (HAYKIN, 2000).

As funções parcialmente diferenciáveis são: função degrau, degrau bipolar ou função sinal, função rampa simétrica. Já as funções totalmente diferenciáveis são: função logística, função tangente hiperbólica, função gaussiana e função linear.

2.2.4 Arquitetura de RNA

A arquitetura de uma rede define a forma como os neurônios estão arranjados uns em relação aos outros, um parâmetro essencial para essa definição leva em consideração o direcionamento das conexões sinápticas do neurônio. SILVA, SPATTI

e FLAUZINO (2019) afirma que uma arquitetura é dividida basicamente em três camadas principais, representadas pela camada de entrada, que é responsável pelo recebimento de dados advindos do meio externo, camadas escondidas ou ocultas que extraem e processam as informações da camada de entrada e camada de saída, que é responsável pela produção e apresentação dos resultados finais processados pelas camadas anteriores.

As principais arquiteturas baseadas em disposição de neurônios e forma de interligação entre eles podem ser divididas em duas categorias: redes *feedward* (alimentação à frente) e redes recorrentes. A rede *feedward* tem como característica o fluxo de informação segue de forma unidirecional da camada de entrada até a camada de saída, ou seja, é um fluxo direto, sem qualquer realimentação. Já nas redes recorrentes as saídas dos neurônios são utilizadas como sinais de entrada para outros neurônios, essa realimentação torna possível o emprego de redes neurais em sistemas dinâmicos e se torna uma ferramenta muito útil para previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2019).

2.2.5 Processo de treinamento de RNA

O processo de treinamento de uma rede neural artificial consiste na aplicação de passos ordenados para ajuste de pesos sinápticos e limiares de ativação de seus neurônios. O objetivo deste treinamento é que a rede aprenda o relacionamento entre entradas e saídas e seja capaz de generalizar soluções (SILVA; SPATTI; FLAUZINO, 2019).

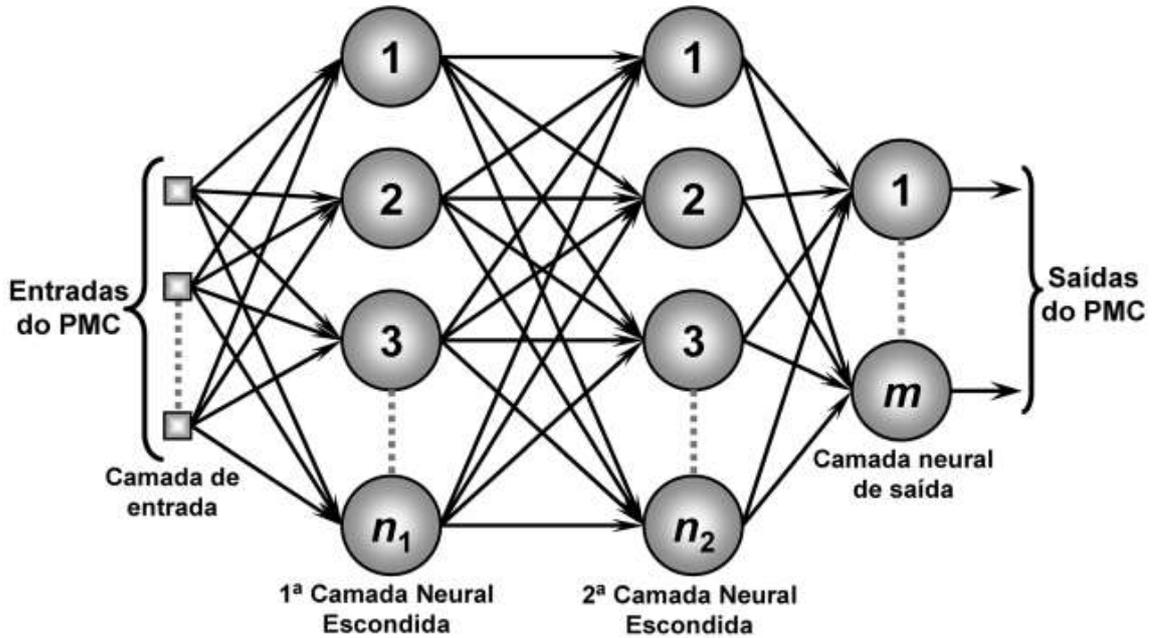
2.2.6 Rede Perceptron multicamadas

A rede *perceptron* multicamadas (PMC) é uma arquitetura de RNA bastante conhecida, caracterizada por uma rede com pelo menos uma camada oculta entre a camada de entrada e a camada neural de saída, a PMC pertence a arquitetura *feedforward*, sem qualquer realimentação entre suas camadas, e seu método de treinamento é do tipo supervisionado, através da utilização do algoritmo de *backpropagation* (HAYKIN, 2000).

O princípio de funcionamento da rede PMC pode ser observado na Figura 4, a camada de entrada não é considerada uma camada neural, pois os dados da primeira camada correspondem aos mesmos dados da entrada. Esses dados de

entrada são ponderados por pesos sinápticos entre a camada de entrada e a primeira camada oculta.

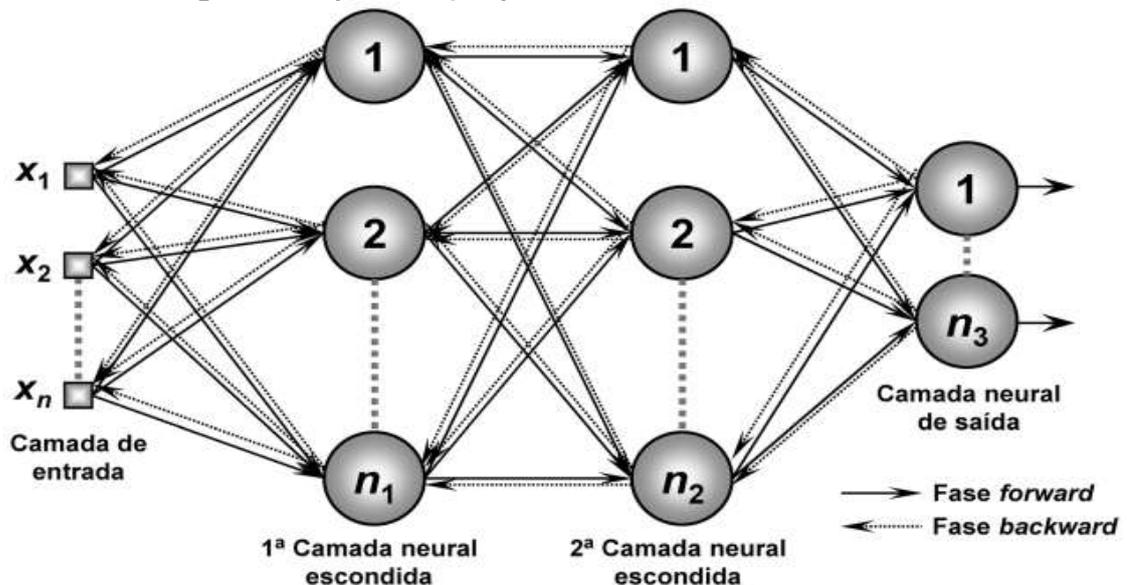
Figura 4 - Representação genérica da rede PMC.



Fonte: SILVA; SPATTI; FLAUZINO (2019).

O processo de treinamento da rede PMC é do tipo supervisionado, ou seja, é inserido um conjunto de entradas onde se conhece as respectivas respostas desejadas. Seu algoritmo de treinamento é baseado no conceito *backpropagation* e pode ser dividido em duas fases que estão ilustradas na Figura 5.

Figura 5 - Representação processo treinamento da rede PMC.



Fonte: SILVA; SPATTI ; FLAUZINO (2019).

Na primeira fase é realizada a propagação a frente (*forward*), na qual os sinais de entrada de um conjunto de amostras de treinamento são inseridos na camada de entrada e propagados até a camada neural de saída, sem qualquer realimentação entre as camadas ou neurônios. Neste momento os pesos sinápticos e limiares de neurônios são escolhidos aleatoriamente e permanecem inalterados, pois o objetivo é obter apenas uma primeira resposta da rede.

Em seguida, as saídas produzidas pela rede são comparadas com as respectivas respostas desejadas das amostras e posteriormente calculados os desvios (erros) para que se execute os ajustes dos pesos e limiares de ativação de todos os neurônios.

Na segunda fase é aplicada a propagação reversa (*backward*), onde o erro calculado é utilizado para ajustar os pesos sinápticos. A propagação do erro ocorre da última camada escondida até as camadas escondidas precedentes, o sentido desta propagação é devido a característica do algoritmo ser baseado no gradiente do erro.

Essas duas fases descritas compõem o algoritmo *backpropagation* e são aplicadas a todas as amostras de treinamento de forma repetitiva até que os valores de saída da RNA sejam inferiores a uma tolerância pré-estabelecida.

O algoritmo de BP é amplamente utilizado no treinamento de redes PMC, porém, em alguns casos pode apresentar convergência lenta e instabilidade da rede em torno de um mínimo da função erro. Muitos outros algoritmos foram desenvolvidos para minimizar este problema, um deles é o algoritmo de Levenberg-Marquardt (LM) que será utilizado neste trabalho.

O algoritmo de LM combina o método de gradiente descendente com o método de Gauss-Newton, ele herda a vantagem da velocidade do algoritmo de Gauss-Newton e a estabilidade do método gradiente descendente (WILAMOWSKI; YU, 2011). O algoritmo de LM possibilita que o treinamento de uma rede PMC seja executado de 10 a 100 vezes mais rápido que o método BP convencional (HAGAN; MENHAJ, 1994).

2.3 O Software MATLAB

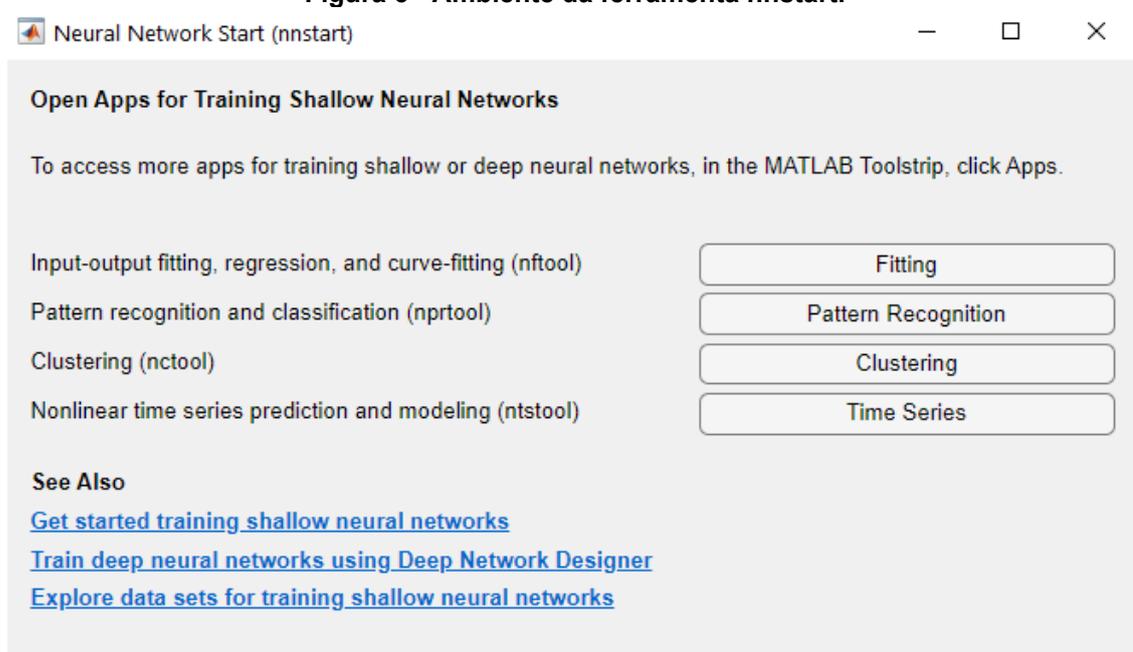
O *software* MATLAB é uma ferramenta utilizada por muitos engenheiros e cientistas para analisar dados, desenvolver algoritmos e criar sistemas que modelem determinada aplicação. Ele conta com linguagem de programação de alto nível, baseado em matrizes e oferece uma vasta biblioteca de *toolboxes* (caixas de

ferramentas) que abrange ferramentas de processamento de sinais, imagens, sistema de controles, *deep learning*, inteligência artificial entre outras (MATHWORKS, 2022).

2.3.1 A Toolbox nstart

A ferramenta *nstart* fornece uma janela com botões de inicialização para aplicativos que utilizam RNA para realizar ajustes, reconhecimento de padrões, agrupamento e séries temporais. Ela também fornece links para listas de conjunto de dados, exemplos e outras informações úteis para começar a utilizá-la.

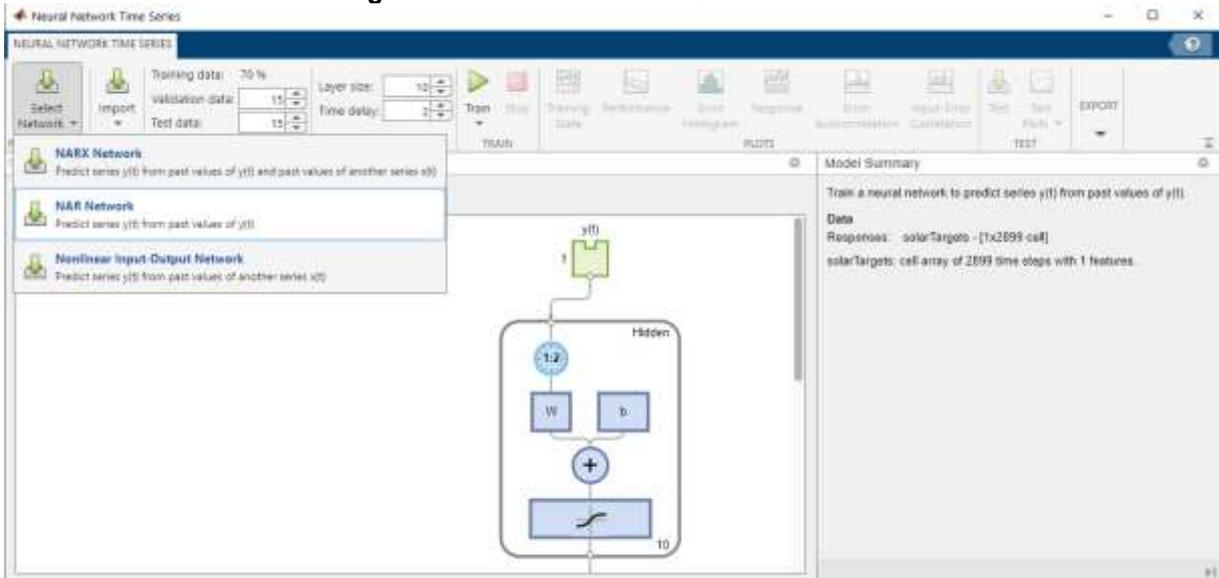
Figura 6 - Ambiente da ferramenta nstart.



Fonte: Autoria própria (2022).

O aplicativo *Neural Net Time Séries (ntstool)* permite criar, visualizar e treinar redes neurais dinâmicas para resolver três tipos diferentes de problemas de séries temporais não lineares, sendo eles: redes NARX (modelo autoregressivo não-linear com entradas exógenas), redes NAR (modelo autoregressivo não-linear) e redes de entrada e saída não lineares. Neste trabalho será utilizado redes NAR, ou seja, será previsto uma série $y(t)$ com base nos valores passados da série $y(t)$.

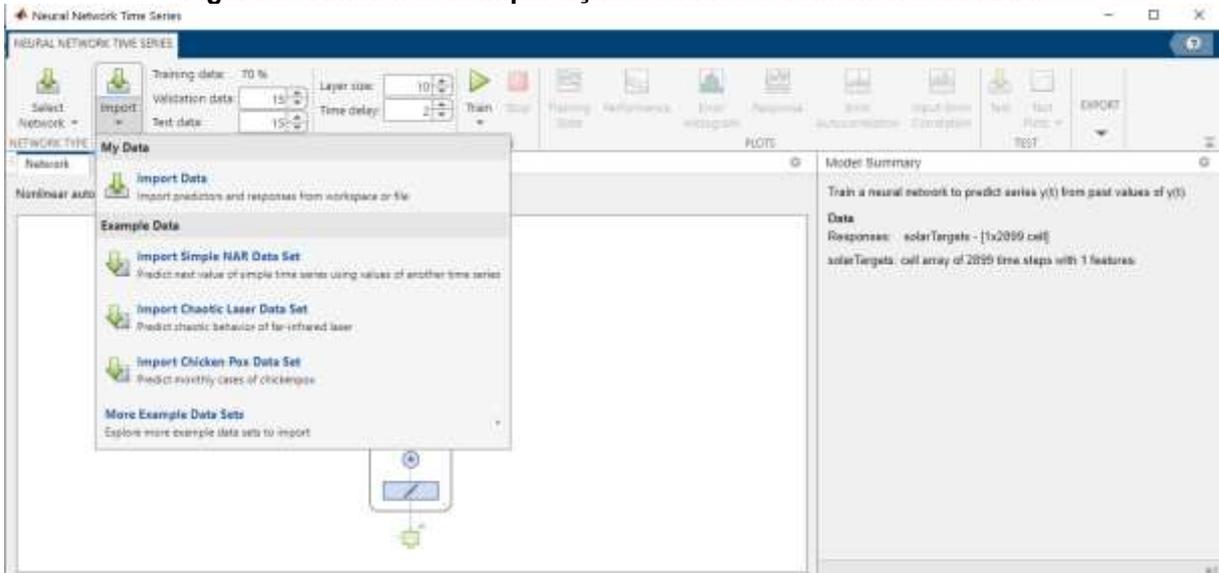
Figura 7 - Ambiente da ferramenta ntstool.



Fonte: Autoria própria (2022).

A partir da escolha do tipo de rede, é necessário importar os dados da área de trabalho do MATLAB ou selecionar conjunto de dados exemplo. Em seguida, divide-se os conjuntos de dados de treinamento, validação e teste e então é possível treinar a rede neural. Foram destinados 80% dos dados para treinamento, 10% para validação e 10% para testes.

Figura 8 - Ambiente de importação de dados e treinamento da RNA.



Fonte: Autoria própria (2022).

Por fim, o ambiente MATLAB permite realizar a comparação de desempenho da rede, utilizando o erro quadrático médio e a análise de regressão.

3. CARACTERÍSTICAS DA SÉRIE TEMPORAL

Este trabalho tem por objetivo desenvolver um modelo de previsão da geração de energia fotovoltaica para os horizontes de curto prazo (30 minutos a frente) utilizando um modelo de redes neurais artificiais. Para isso, este capítulo apresentará detalhadamente toda manipulação realizada nos dados. Desde a aquisição, pré-processamento, decomposição da série temporal residual e classificação preliminar baseada em estações climáticas.

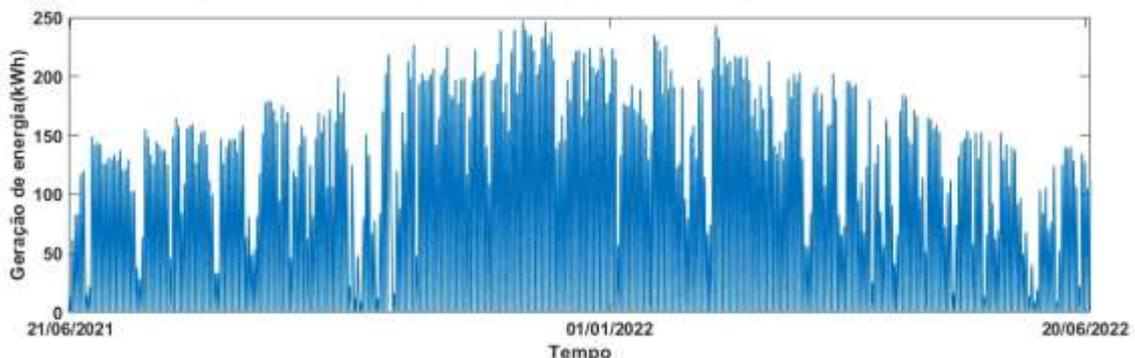
A geração de energia fotovoltaica pode variar de acordo com as estações climáticas, ou com as condições climáticas (temperatura, chuva, umidade) do local. Com objetivo de melhorar o modelo de previsão diante de tal sazonalidade, será aplicado a hipótese de classificação preliminar nos dados de entrada da rede, o critério de classificação é com base nas estações climáticas do ano.

3.1 Aquisição dos dados

Foram coletadas 140341 amostras com intervalos de 2 minutos durante o período de 21 de junho de 2021 à 20 de junho de 2022, que compreendem 365 dias. A coleta de dados foi realizada de forma online mediante o ambiente *Good We Sems Portal*, ferramenta disponibilizada pelo fornecedor do sistema.

O portal citado anteriormente disponibiliza informações como tensão, corrente, frequência de saída e modo de operação do inversor, temperatura das placas, MPPT (*Maximum Power Point Tracking*), geração de energia diária e entre outras. Neste trabalho foi utilizada apenas a variável “geração de energia diária (kWh)”, que corresponde a potência de saída do inversor solar, como variável de entrada da rede. Esta variável está representada na Figura 9.

Figura 9 - Série temporal da geração de energia elétrica diária.

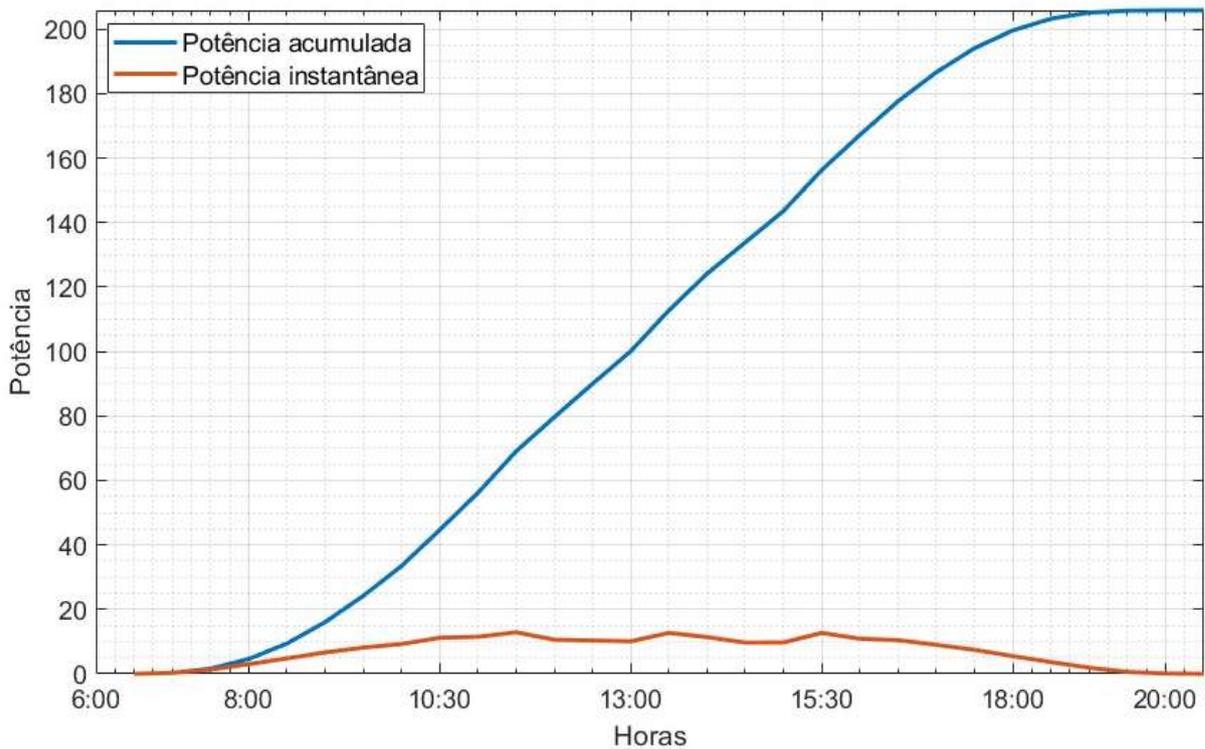


Fonte: Autoria própria (2022).

Como pode ser visto na Figura 9, a ferramenta disponibilizou a leitura da potência de saída que compreende um intervalo de 0kWh à 250 kWh. Para este último valor, trata-se da geração acumulada durante o dia, logo, os dados apresentam um comportamento acumulativo ao longo de um dia e o pico diário está localizado no final da tarde. Deste modo, os dados não apresentam a característica de “geração instantânea” dada pela diferença do instante $t_{atual} - t_{2\text{ minutos atrás}}$, para este caso o pico de geração diária estaria localizado próximo as 12h00, onde a radiação solar é frequentemente maior.

A forma com que os dados podem ser coletados nas estações fotovoltaicas estão apresentados na Figura 10, onde a potência acumulada apresenta o comportamento dos dados da série temporal que será utilizada neste trabalho, e a potência instantânea representa um comportamento presente nas demais literaturas.

Figura 10 - Potência de saída do dia 27/12/2022 representado de duas formas diferentes.



Fonte: Autoria própria (2022).

Além disso, o inversor solar apresentou três modos de operação, sendo eles: normal, em espera e em falha. O modo normal é caracterizado pelo momento quando o inversor solar está em modo de operação ideal, ou seja, está convertendo tensão contínua em tensão alternada. O modo em falha significa que o inversor tem condições para estar operando no modo normal, mas por algum motivo, seja ele surto de tensão

ou corrente, mau contato nos terminais e entre outras anormalidades, o inversor entrou em falha como modo de proteção.

Por fim, o modo em espera é representado pelo tempo de transição entre o momento em que o sistema está inoperante, ou seja, não está gerando energia, e o momento que inicia a geração de energia. Essa transição ocorre geralmente nos inícios das manhãs e nos finais de tarde.

3.2 Pré-processamento dos dados

Observou-se que durante o período de 365 dias, o inversor solar apresentou 116 leituras como modo de operação “em falha”. Neste modo de operação o sistema assume estado inoperante e registra periodicamente a última leitura com modo de operação normal, até que a falha seja reiniciada ou cesse a radiação solar sobre as placas. Como esses dados incongruentes representam apenas 0,090% da base de dados e, os valores das leituras foram replicados de acordo com a última amostra com modo de operação regular, optou-se por não retirar estes dados da série temporal.

As amostras em que o inversor apresentou modo de operação “em espera” também foram mantidas na série temporal. Apesar de não representar um período de geração de energia, estes dados apresentam características intrínsecas para a série. De forma analítica, entendeu-se que estas amostras representam o momento de transição do sistema de operante para inoperante, isto é, momentos característicos de finais de tarde, onde a radiação solar cessa permanentemente.

Além disso, apesar dos dados apresentarem intervalo de amostragem de 2 minutos, observou-se que o horário de início e fim dos registros da geração diária se mostrou variante, como por exemplo, determinados dias o portal registrou valores a partir das 7h10 e em outros dias registrou a partir do horário 6h18. Essa variação de horário de inícios dos registros compromete a acuracidade das previsões de série temporal pois os dados devem ser organizados de forma que a amostra índice n de um dia deve corresponder ao mesmo horário da amostra n de todos os dias. Para isso, se faz necessário um pré-processamento dos dados.

Para corrigir isso, foi estabelecido um horário inicial e final para registro dos dados diários. O horário inicial foi definido como 06h00, e o final 20h00. Esses horários foram estabelecidos, respectivamente, com base no menor e maior horário de registro da base de dados. A fim manter a acuracidade dos dados, para os dias em que o início

da geração começou após das 6h00, foi atribuído 0 kWh para todos os instantes até o primeiro instante de geração de energia.

Da mesma forma, para os dias em que a geração de energia cessou antes das 20h00, foi atribuído o valor da última variação de geração registrada. Por exemplo, se em determinado dia o último valor registrado foi 150 kWh para o instante 18h00, foi atribuído este mesmo valor para os instantes subsequentes até as 20h00.

Vale ressaltar que os dados foram disponibilizados de forma acumulativa, e como não houve variação na potência de saída após o horário das 18h00 repetir o último valor de potência acumulada registrada é equivalente à atribuição de ausência na potência de saída da rede.

Além da divergência do horário inicial dos registros, houve outra incompatibilidade no horário dos registros ao longo do dia. Foi identificado que haviam registros 8h11, 8h13 e 8h15 para um dia e em outro dia haviam registros para os horários 8h12, 8h14 e 8h16 que implica em um atraso de 1 minuto comparando as amostras. Para corrigir isso, a série temporal foi novamente modelada utilizando o seguinte critério: para o exemplo anterior, o instante 8h12 (que não existia na base de dados) foi considerado a média dos instantes 8h11 e 8h13, da mesma forma, o instante 8h14 foi considerando a média entre os instantes 8h13 e 8h15. Desta forma a base de dados passou a deter um período de amostragem de 1 minuto no intervalo de 6h00 às 20h00 para todos os dias da série temporal.

Com objetivo de melhorar o processamento da série, visto que a remodelagem anterior multiplicou por 2 o número de amostras, optou-se por reduzir a quantidade de dados reduzindo o período de amostragem para 30 minutos. Essa redução foi realizada selecionando os instantes múltiplos de 30 minutos entre o período das 6h00 e 20h00. Como os dados tem características acumulativas, está manipulação mantém a acuracidade dos dados embora diminua sua resolução.

Assim, a nova série temporal ficou definida como 10585 amostras com período de amostragem de 30 minutos, com início às 6h00 e término as 20h00. Portanto, dada a manipulação dos dados, a previsão da rede neural será de 30 minutos a frente.

Tabela 1 – Alteração do período de amostragem.

Horário	Potência Diária Acumulada	Horário	Nova Série de Potência
...	...	13:00	46,50
12:58	45,80	13:30	51,80
12:59	46,15		
13:00	46,50		
13:01	47,40		
13:02	47,46		
...	...		
13:28	51,50		
13:29	51,65		
13:30	51,80		
13:31	52,10		
13:32	52,40		
...	...		

Fonte: Autoria própria (2022).

3.3 Classificação preliminar dos dados

A série temporal representada pela geração de energia da estação fotovoltaica é fortemente influenciada por fatores climáticos e estes fatores possuem uma sazonalidade de acordo com as estações do ano. Por esta razão, foi aplicada uma classificação preliminar dos dados baseada nas estações climáticas do ano.

Os períodos de início e fim das estações foram definidos conforme informações do Instituto de Astronomia, Geofísica e Ciências Atmosféricas e estão descritas na Tabela 2.

Tabela 2 - Datas de início e fim das estações climáticas.

Estações	Início	Fim
Inverno	21 de junho de 2021 (0h32)	22 de setembro de 2021 (16h21)
Primavera	22 de setembro de 2021 (16h21)	21 de dezembro de 2021 (12h59)
Verão	21 de dezembro de 2021 (12h59)	20 de março de 2022 (12h33)
Outono	20 de março de 2022 (12h33)	21 de junho de 2022 (6h14)

Fonte: Autoria própria (2022).

Feita a classificação preliminar, a série temporal original foi dividida em quatro séries temporais designadas como: série temporal de inverno, série temporal de primavera, série temporal de verão e série temporal de outono.

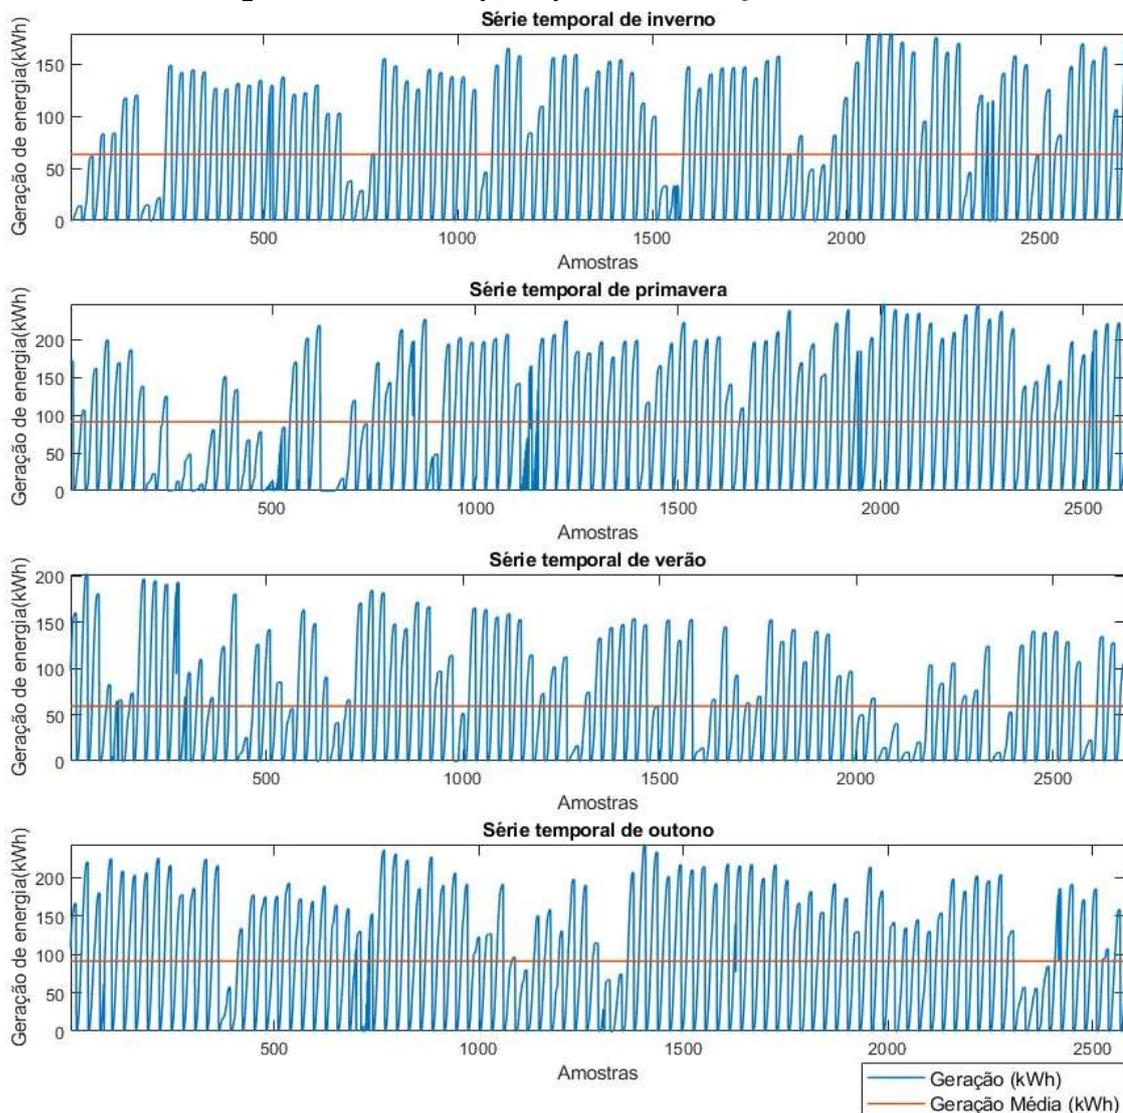
A quantidade de amostras por série foi apresentada na Tabela 3 e a representação gráfica de cada série pode ser vista na Figura 11. Vale destacar que de acordo com a Tabela 2 a quantidade de amostras por série é equilibrada, nenhuma série tem um número mais ou menos expressivo de amostras. Logo, este equilíbrio é

relevante para uma análise estatística, pois contribui para uma análise sem viés, ou seja, um conjunto de amostras não tem vantagem sobre as outras em relação à quantidade.

Estações	Quantidade de Amostras
Série temporal de inverno	2719
Série temporal de primavera	2603
Série temporal de verão	2580
Série temporal de outono	2683

Fonte: Autoria própria (2022).

Figura 11 - Série temporal para cada estação climática.

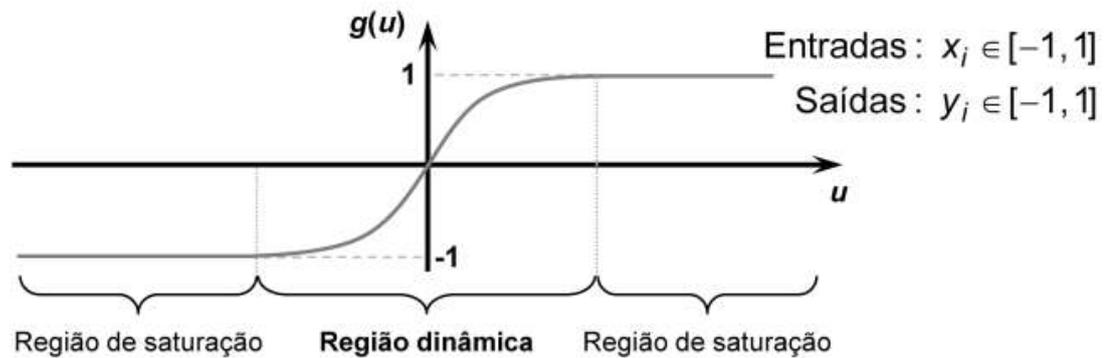


Fonte: Autoria própria (2022).

3.4 Processamento dos dados

De acordo com SILVA; SPATTI e FLAUZINO (2019), o pré-processamento das amostras de treinamento e teste contribui com uma melhoria do desempenho de treinamento. A melhoria se dá em escalonar as amostras para satisfazer a faixa de variação dinâmica das funções de ativações, de forma que evite a saturação dos neurônios, conforme ilustrado na Figura 11.

Figura 12 - Domínios de normalização para a função de ativação tangente hiperbólica.

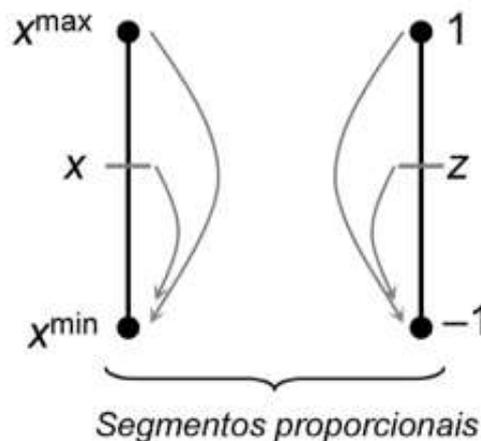


Fonte: Adaptado de Flauzino (2022).

Para satisfazer a faixa de variação dinâmica mencionada anteriormente, foram padronizadas as amostras de um intervalo fechado $[x_{\min}, x_{\max}]$ para um intervalo fechado de $[-1, 1]$, conforme Figura 13 e com base no teorema de Tales, descrito pela Equação 2:

$$z = 2 \cdot \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad (2)$$

Figura 13 - Conversão de segmentos proporcionais.



Fonte: Adaptado SILVA, SPATTI e FLAUZINO (2019).

3.5 Decomposição dos dados

Neste trabalho foi aplicado o método de decomposição de série temporal desenvolvido por Aguirre et al., (2008). O autor sugere a segmentação dos dados em dois subconjuntos de amostras, o primeiro conjunto é composto por dados que possuem comportamento puramente estáticos e, segundo ele, não é necessário recorrer a modelos não lineares para realizar a previsão dinâmica. Já o segundo conjunto considera os dados que possuem comportamento atípico, ou seja, não apresentam correlações seriais. Neste último caso torna-se necessário recorrer a modelos não lineares.

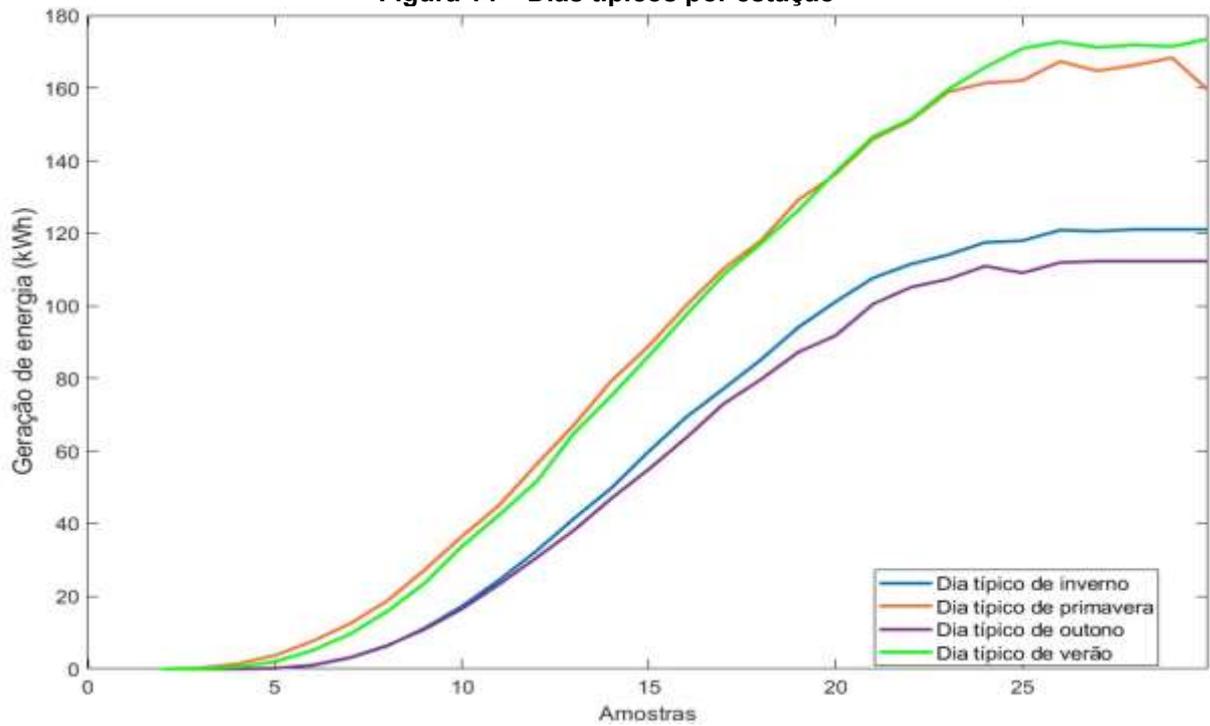
Portanto, para realizar tal decomposição, foi construída uma série temporal média a partir da série temporal original e, posteriormente, obtido uma série temporal residual dada pela diferença das duas series (subtrai-se a série média da série original). A série residual será utilizada como parâmetro de entrada da RNA.

Desta forma, após aplicada a classificação preliminar da série de acordo com as estações climáticas, foi extraído o comportamento médio de cada série temporal com base na média de geração diária ao longo do dia. O dia típico de cada estação climática foi construído com base na média dos instantes amostrados de cada dia, por exemplo, média de todos os dias de verão às 6h00, 6h30 ... 20h00.

O comportamento médio diário resultou em quatro dias típicos, sendo eles, dia típico de inverno, dia típico de primavera, dia típico de verão e dia típico de outono. Na Figura 14 pode-se observar o comportamento de cada dia típico.

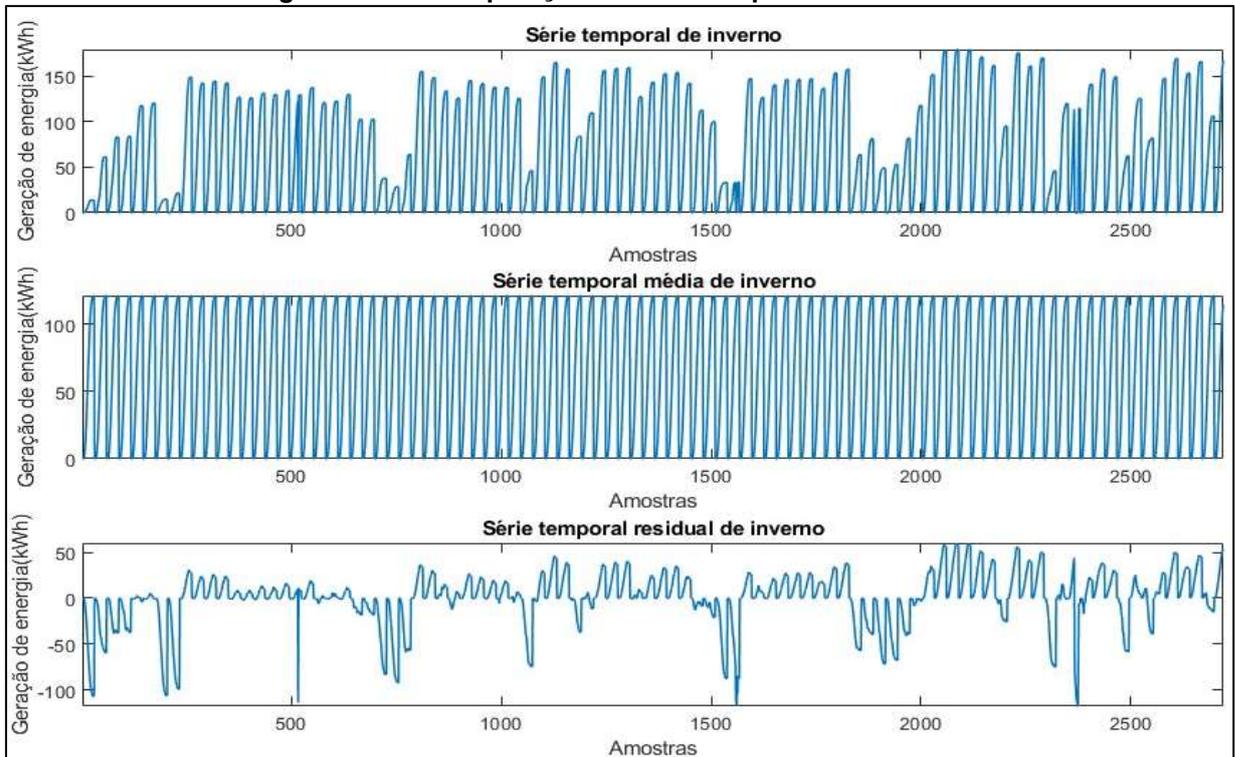
Por fim, o comportamento atípico da série foi obtido pela subtração das séries médias das respectivas séries originais, resultando então uma série residual para cada estação climática. Os gráficos das figuras 15, 16, 17 e 18 ilustram essas séries por estação.

Figura 14 – Dias típicos por estação



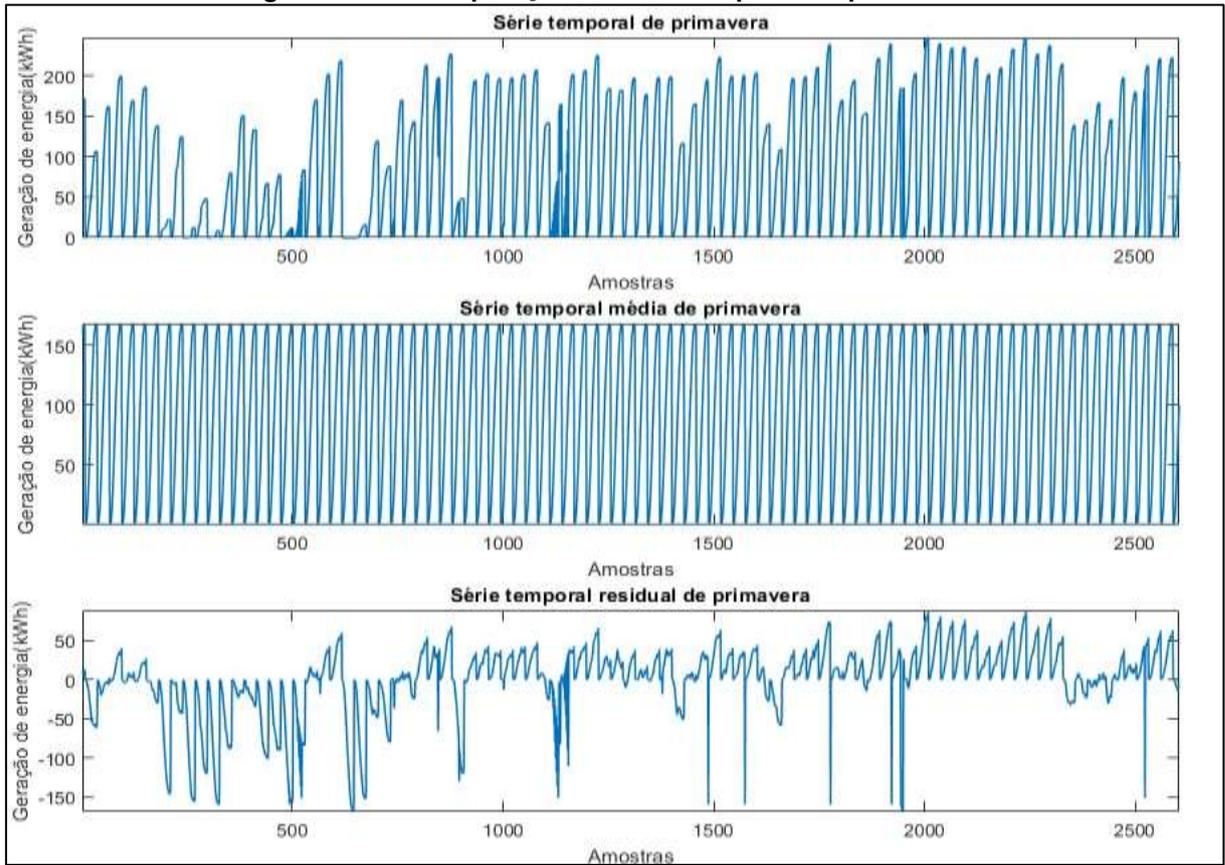
Fonte: Autoria própria (2022).

Figura 15 - Decomposição da série temporal de inverno.



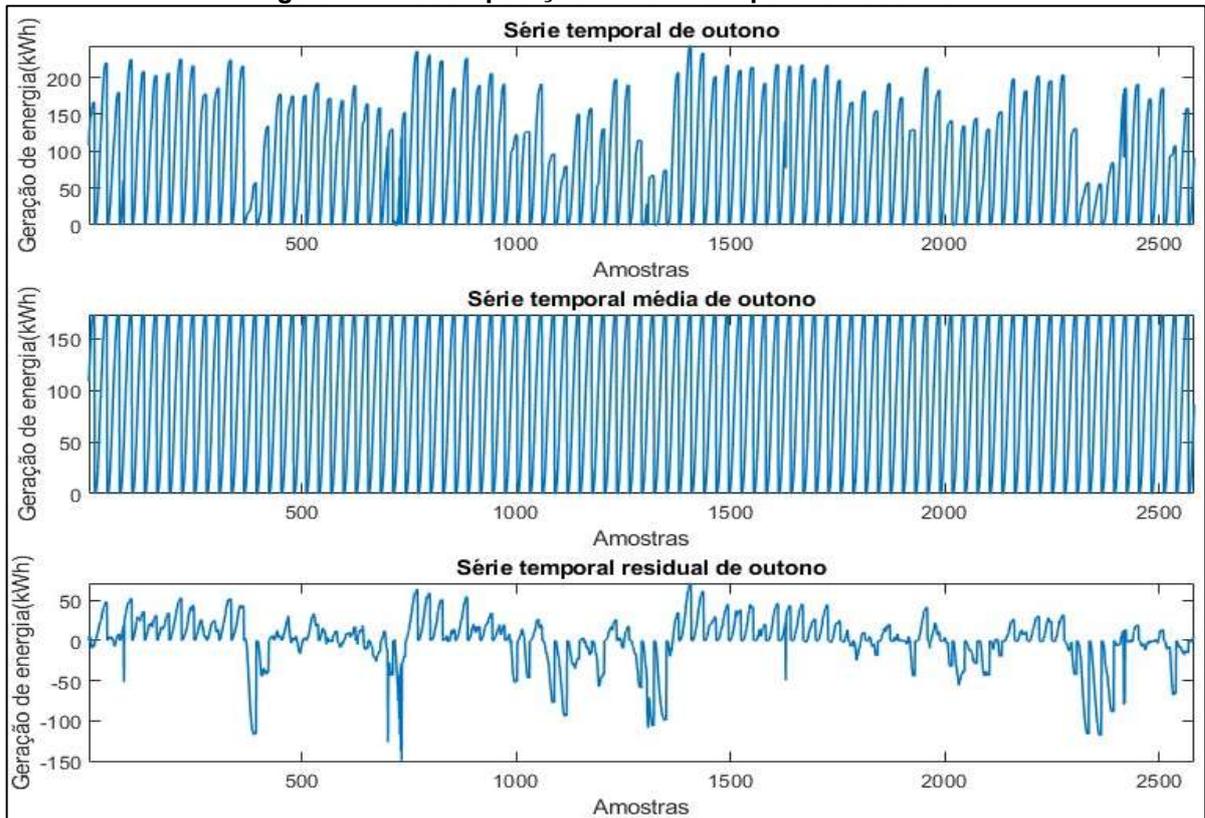
Fonte: Autoria própria (2022).

Figura 16 - Decomposição da série temporal de primavera.

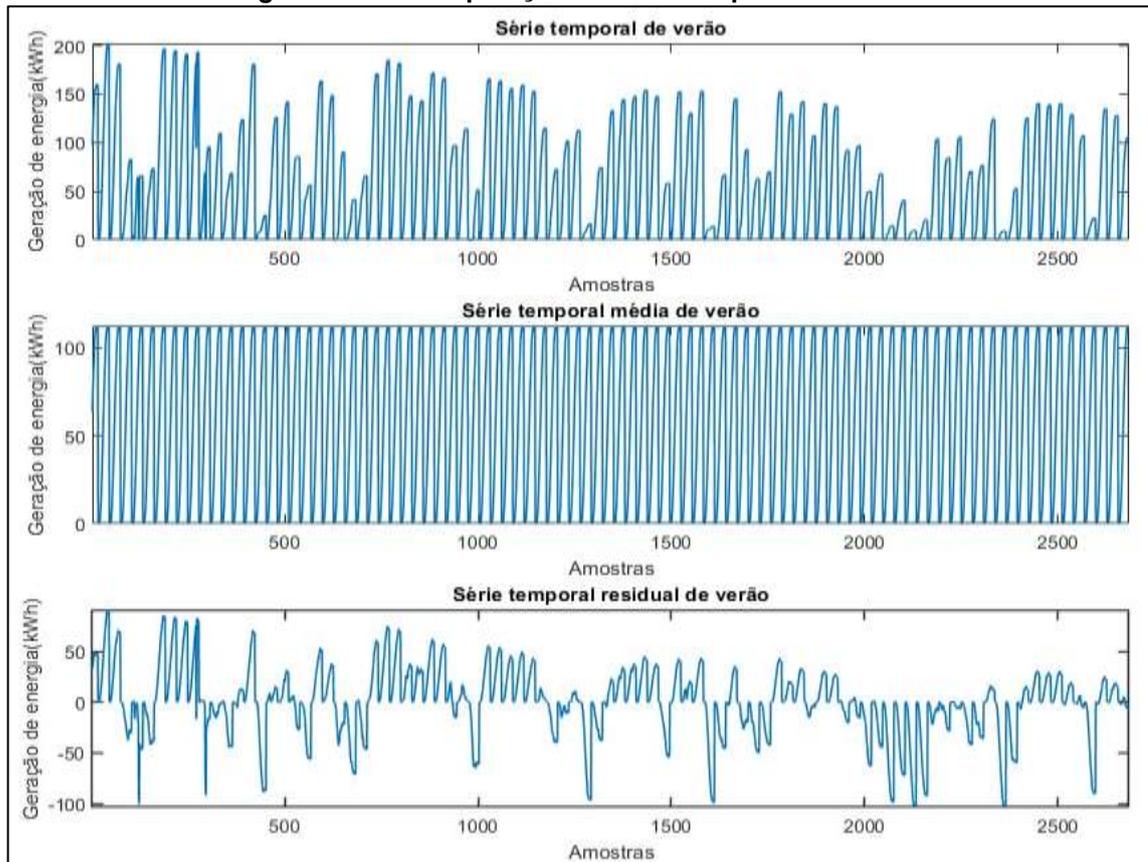


Fonte: Autoria própria (2022).

Figura 17 - Decomposição da série temporal de outono.



Fonte: Autoria própria (2022).

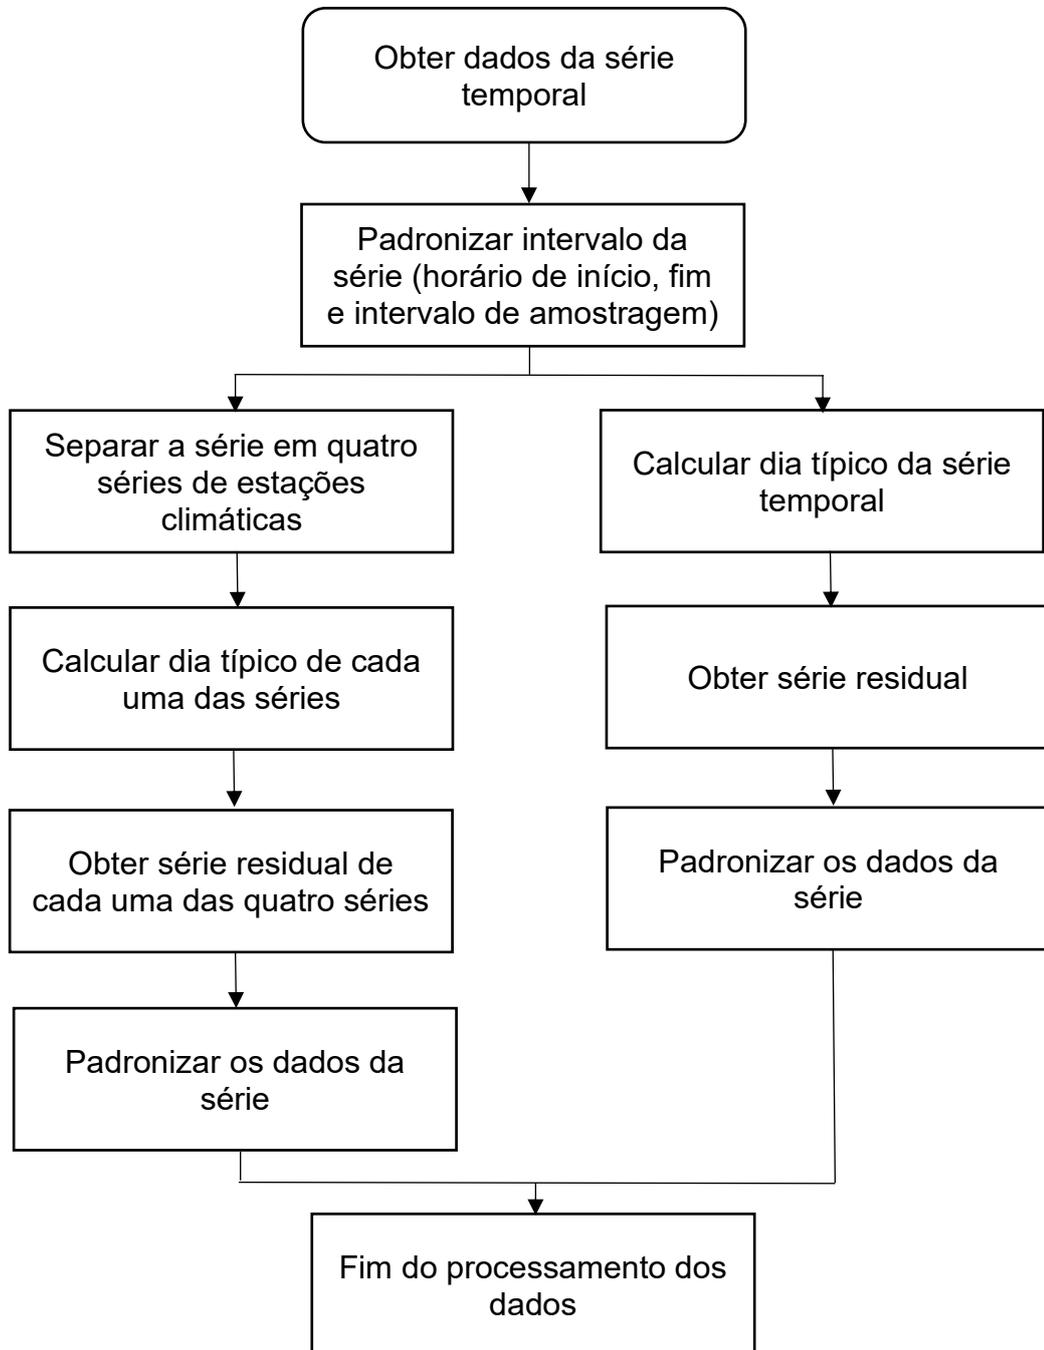
Figura 18 - Decomposição da série temporal de verão.

Fonte: Autoria própria (2022).

3.6 Fluxograma do processamento dos dados

O fluxograma a seguir detalha toda a manipulação descrita no decorrer do capítulo apresentado.

Figura 19 - Fluxograma do tratamento realizado nos dados.



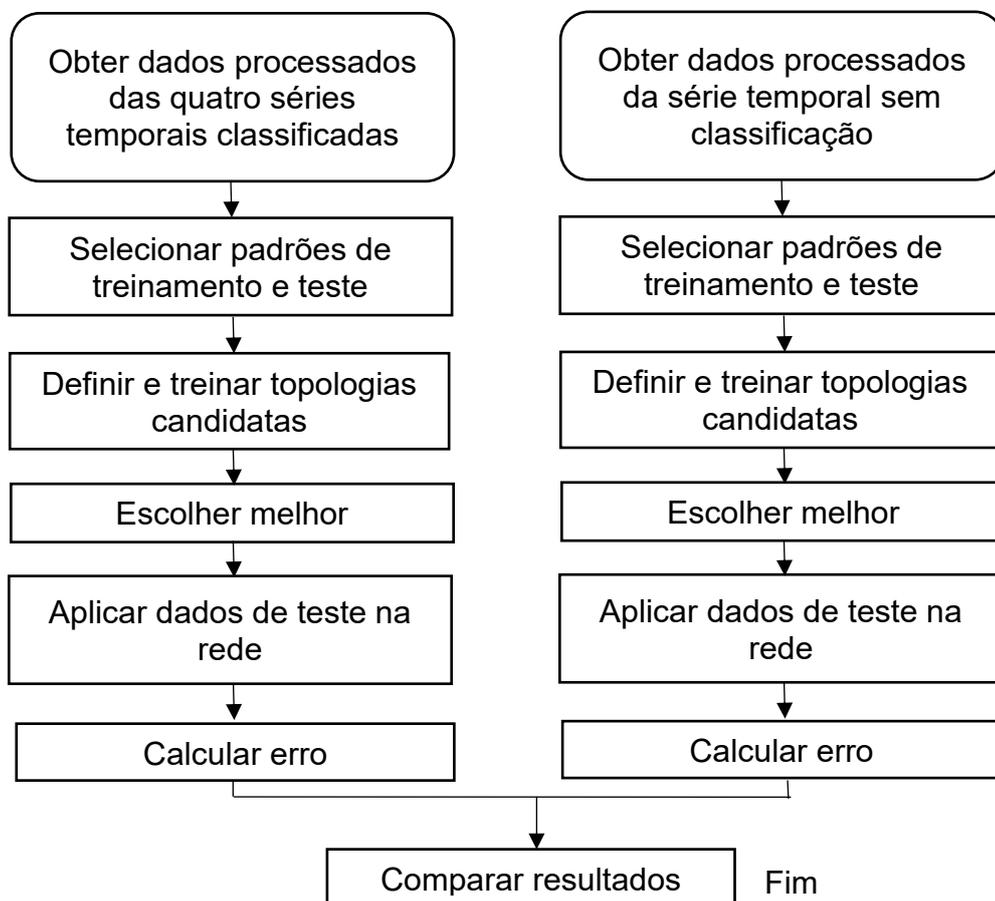
4. IMPLEMENTAÇÃO DO MÉTODO DE PREVISÃO PROPOSTO

Este capítulo apresenta o fluxograma de implementação do método de previsão, as ferramentas computacionais e matemáticas utilizadas em seu desenvolvimento, além dos métodos estatísticos que serão utilizados para avaliação do desempenho da previsão.

4.1 Fluxograma da validão experimental

O fluxograma a seguir detalha como serão as etapas de implementação deste trabalho.

Figura 20 - Fluxograma da validação experimental.



Fonte: Autoria própria (2022).

4.2 Definição dos parâmetros de desempenho utilizados

Esta seção abrange os parâmetros de desempenho que irão definir se a rede apresentou ou não um bom desempenho.

4.2.1 Análise do erro

Para avaliar o desempenho de um modelo de previsão é necessário definir uma medida de erro que seja replicável para todos os modelos. Para este trabalho, o erro de previsão será dado pela diferença entre o valor atual da série e o valor que foi previsto pela RNA. Os principais parâmetros de avaliação de erros são:

- Erro quadrático médio (*mean square error* (MSE))

$$MSE = \frac{1}{N} \sum_{k=1}^N (x(k) - \hat{x}(k))^2 \quad (3)$$

Onde, N é o tamanho do conjunto de validação, $x(k)$ é o valor do elemento k da série temporal e $\hat{x}(k)$ é o valor previsto da série temporal para o elemento $x(k)$. Neste trabalho será utilizado o MSE para comparar o desempenho das RNAs e o melhor desempenho será aquele que apresentar o menor MSE no conjunto de testes.

4.2.2 Análise de resíduos

Os resíduos na análise do desempenho de uma série temporal são definidos pela diferença entre o valor esperado e o resultado previsto no método de previsão. Para este trabalho, o resíduo e_t é dado pela diferença entre a geração de energia fotovoltaica conhecida $y(k)$ e a geração de energia fotovoltaica prevista $\hat{y}(k)$.

$$e_t = y(k) - \hat{y}(k)$$

A análise dos resíduos é importante para verificar o desempenho do modelo de previsão proposto, um modelo é considerado bom se apresentar resíduos com coeficientes de correlação próximo de zero. Isso implica que se houver correlação entre os resíduos e os valores da variável de estudo, existe a possibilidade de haver informações determinísticas na série que deviam ser utilizadas na previsão. Além disso, os resíduos devem possuir média zero, que indica que a previsão não é tendenciosa (HYNDMAN; ATHANASOPOULOS, 2018).

4.2.3 Overfitting

A topologia de uma rede neural artificial está diretamente ligada ao seu desempenho, pois, o aumento indiscriminado de neurônios nas camadas intermediárias não garante um bom aprendizado para a RNA. Em alguns casos, esse aumento de neurônios pode levar a rede à uma memorização excessiva (*overfitting*),

em que acaba apenas reproduzindo respostas vistas no período de treinamento (FLAUZINO et al., 2019).

Uma maneira de identificar se está acontecendo o fenômeno de *overfitting* é verificar se o erro quadrático durante a fase de aprendizado é baixo, enquanto, durante a fase de teste o erro assume valores bem elevados (FLAUZINO et al., 2019).

5. RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos na previsão das séries classificadas como séries temporais de inverno, primavera, verão e outono e também da série temporal sem classificação preliminar.

5.1 Previsão da série temporal de inverno

O processo de treinamento e teste para previsão desta série seguiram os passos indicados no Capítulo 4. A Tabela 4 apresenta os resultados obtidos utilizando diferentes topologias considerando de 2 a 15 neurônios.

Para cada topologia, a rede foi treinada 30 vezes e foi considerado como melhor resultado a topologia que apresentou menor erro durante a fase de teste.

Tabela 4 – Resultados (MSE) de treinamento e teste da série temporal de inverno.

Neurônios na camada oculta	Épocas	Teste	Validação	Treinamento
2	6	0,003916	0,005763	0,010769
3	6	0,003270	0,005020	0,011810
4	6	0,003656	0,019745	0,008697
5	6	0,002186	0,008088	0,009496
6	6	0,004422	0,008669	0,009565
7	6	0,002788	0,008941	0,009497
8	6	0,002632	0,013141	0,008890
9	6	0,003517	0,003195	0,010369
10	6	0,002083	0,012924	0,009239
15	6	0,003535	0,009112	0,009027

Fonte: Autoria própria (2022).

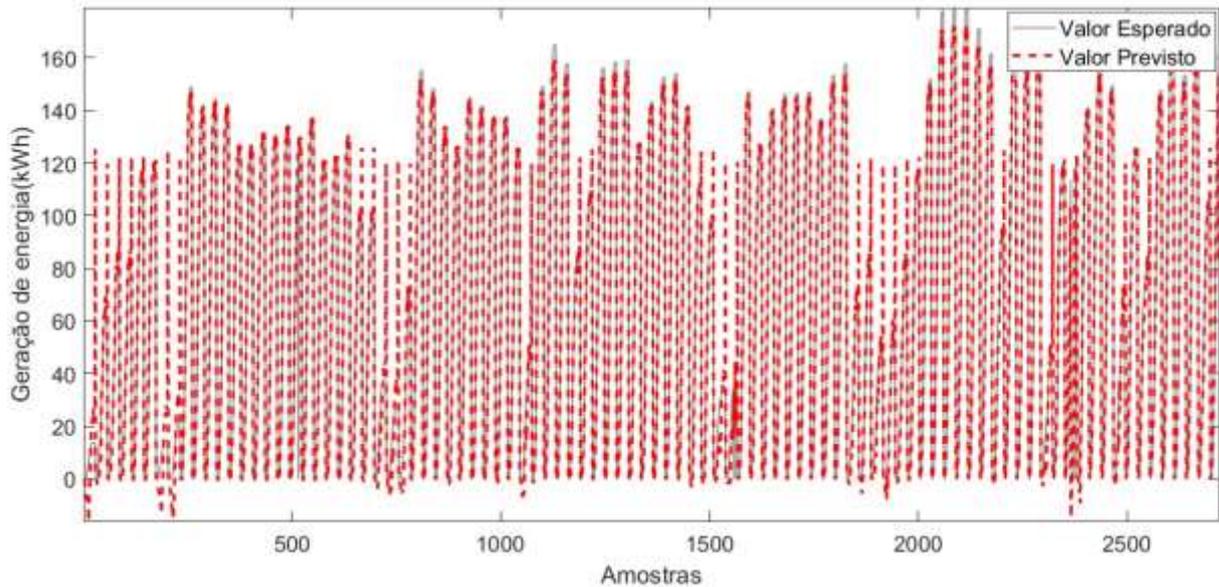
Dentre os resultados obtidos, a topologia que apresentou maior desempenho durante o processo de teste foi a topologia com 10 neurônios na camada escondida, que corresponde a um MSE de 0,002083. Os resultados da previsão da topologia com maior desempenho podem ser vistos nas figuras 20, 21, 22, 23 que correspondem aos resultados obtidos na previsão, recorte com maior resolução dos resultados da previsão, histograma de resíduos da previsão e função autocorrelação dos resíduos, respectivamente.

Do ponto de vista de custo computacional, todas as topologias convergiram rapidamente tendo o melhor resultado na 6ª iteração e, também, pode ser observado na Figura 21 que os maiores erros da previsão se manifestaram nos momentos de picos e vales onde ocorreram variações abruptas. Esse fenômeno poderia ser

minimizado caso tivesse sido optado por utilizar uma série temporal que representa a potência de saída instantânea e não a potência acumulada ao longo do dia.

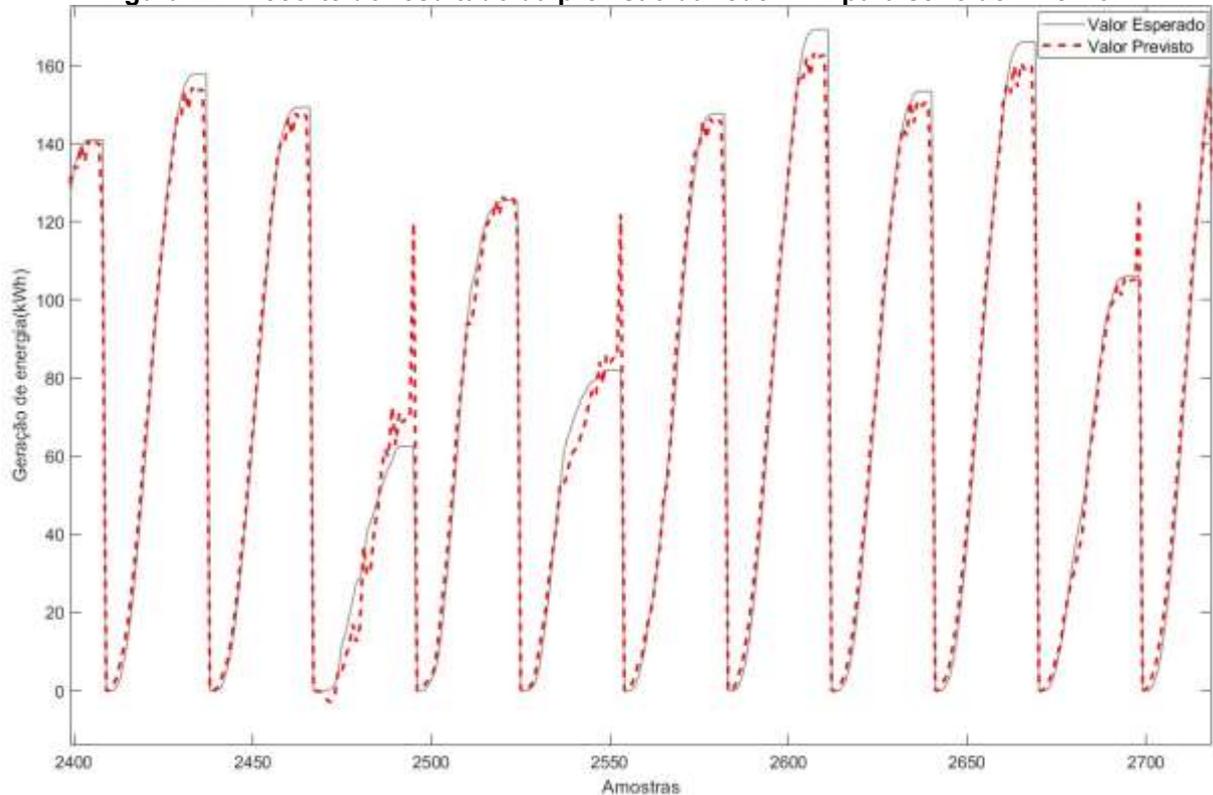
Além disso, nota-se pela Figura 22 e 23 que os resíduos apresentaram uma média próxima de zero e não apresentaram correlação significativa.

Figura 21 - Resultado da previsão da rede MPL para série de inverno.



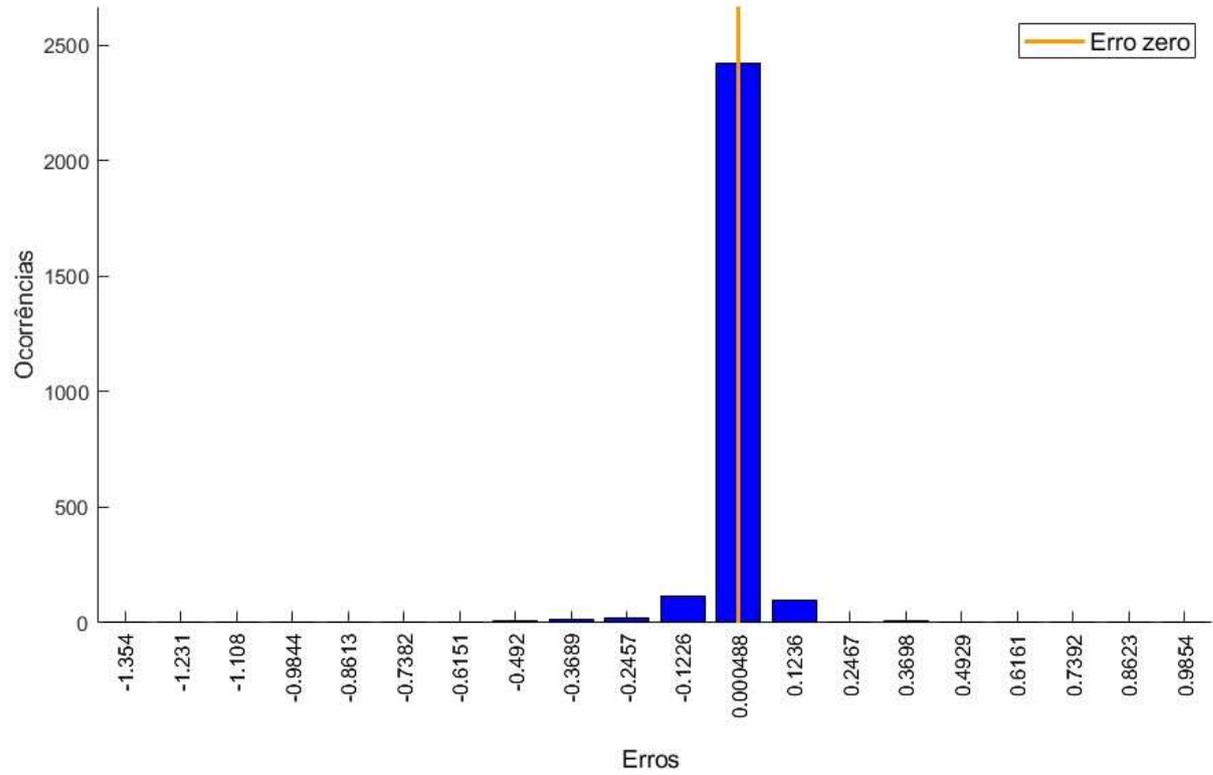
Fonte: Autoria própria (2022).

Figura 22 - Recorte do resultado da previsão da rede MPL para série de inverno.



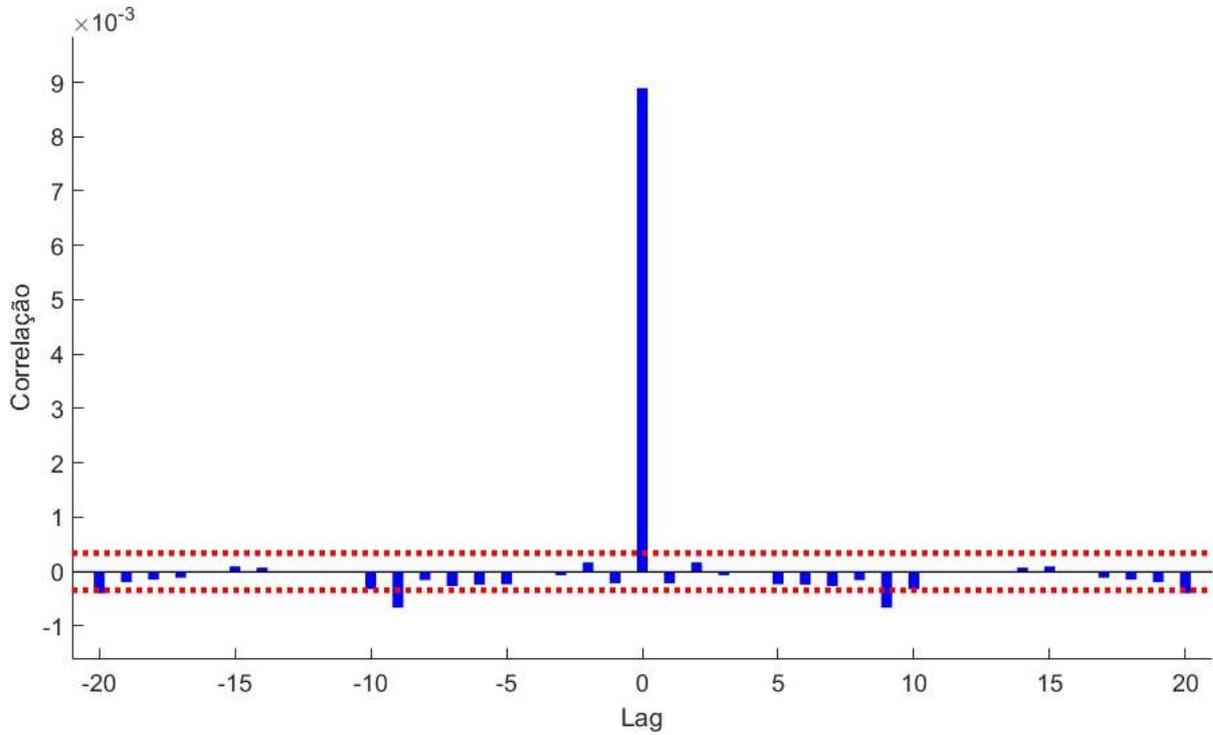
Fonte: Autoria própria (2022).

Figura 23 - Histograma de resíduos série temporal de inverno.



Fonte: Autoria própria (2022).

Figura 24 - Função autocorrelação dos erros de previsão da série temporal de inverno.



Fonte: Autoria própria (2022).

5.2 Previsão da série temporal de primavera

O processo de treinamento e teste para previsão desta série seguiram os passos indicados no Capítulo 4. A Tabela 4 apresenta os resultados obtidos utilizando diferentes topologias considerando de 2 a 15 neurônios.

Tabela 5 - Resultados de treinamento e teste da série temporal de primavera.

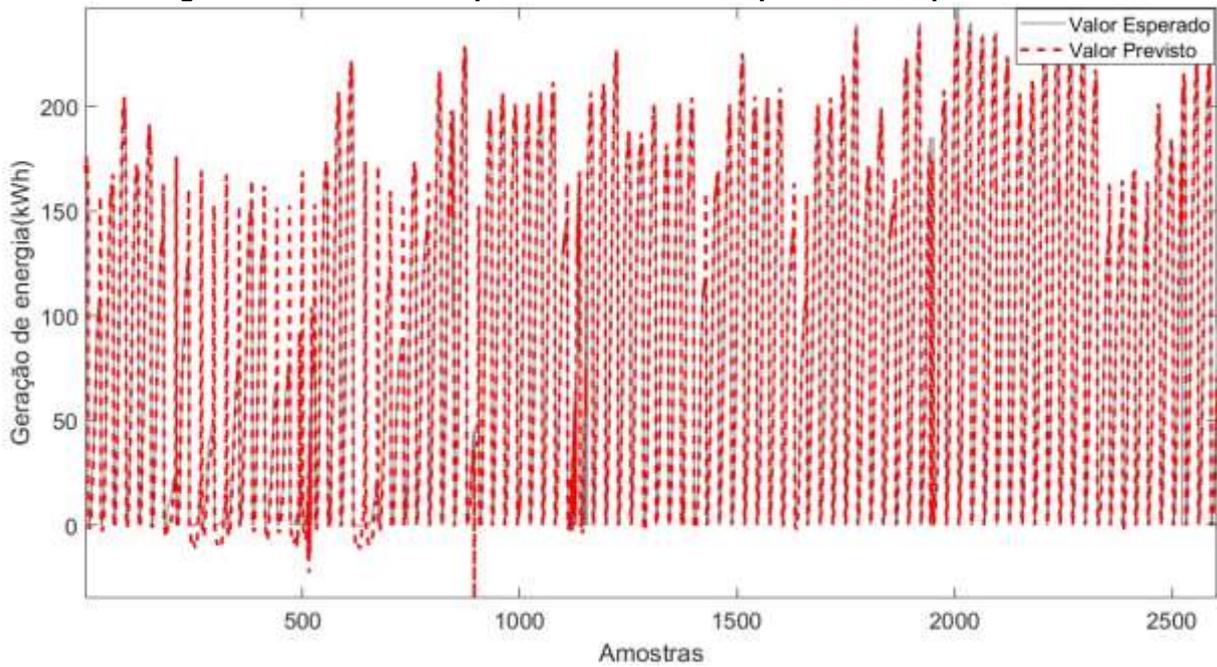
Neurônios na camada oculta	Épocas	Teste	Validação	Treinamento
2	6	0,00683	0,01511	0,02021
3	6	0,00528	0,01076	0,02054
4	6	0,00483	0,01324	0,01798
5	6	0,00812	0,01532	0,01807
6	6	0,00591	0,01324	0,01773
7	6	0,00194	0,00220	0,01218
8	6	0,00451	0,03486	0,01142
9	20	0,00424	0,00767	0,01641
10	13	0,00569	0,00937	0,01580
15	6	0,00223	0,01201	0,01220

Fonte: Autoria própria (2022).

Dentre os resultados obtidos, a topologia que apresentou maior desempenho durante o processo de teste foi a topologia com 7 neurônios na camada escondida, que corresponde a um MSE de 0,00194. Os resultados da previsão da topologia com maior desempenho podem ser vistos nas figuras 24, 25, 26, 27 que correspondem aos resultados obtidos na previsão, um recorte com maior resolução dos resultados, histograma de resíduos da previsão e função autocorrelação dos resíduos, respectivamente.

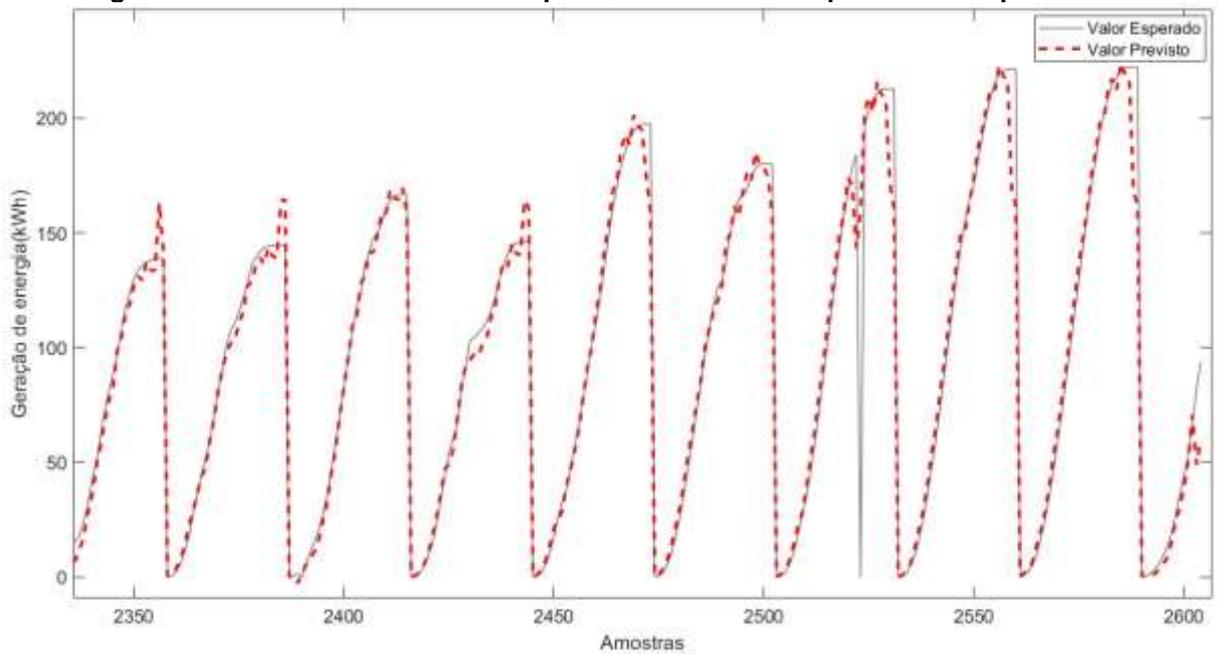
Além disso, pode ser observado na Figura 25 que os maiores erros da previsão se manifestaram nos momentos de picos e vales onde ocorreram variações abruptas e resíduos apresentaram uma média próxima de zero e não apresentaram correlação significativa.

Figura 25 - Resultado da previsão da rede MPL para série de primavera.



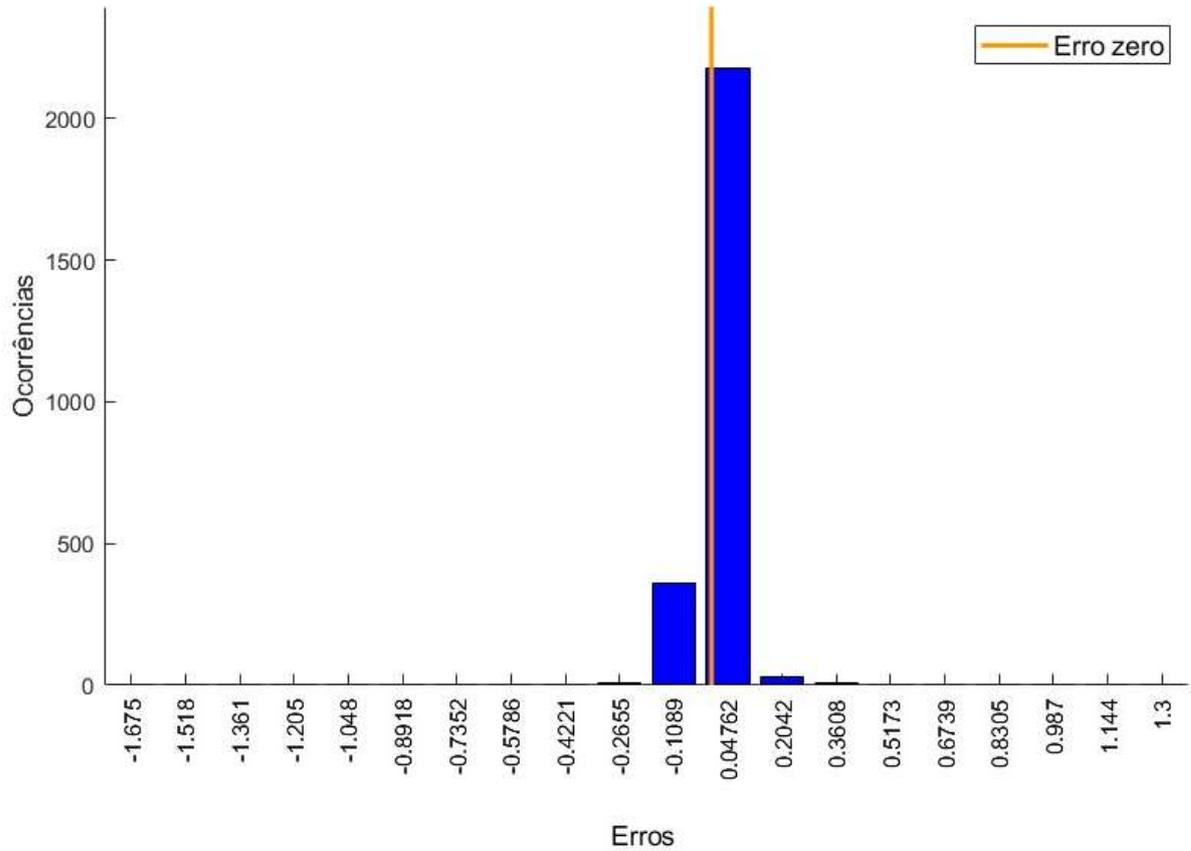
Fonte: Autoria própria (2022).

Figura 26 - Recorte do resultado da previsão da rede MPL para série de primavera.



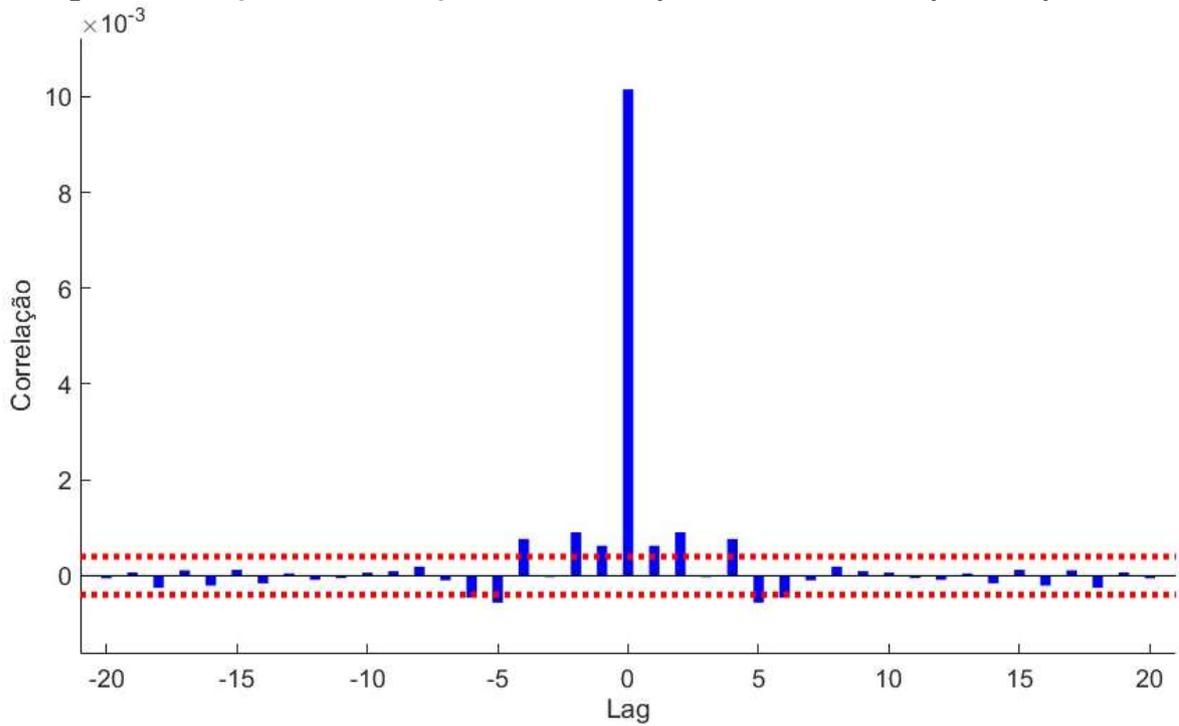
Fonte: Autoria própria (2022).

Figura 27 - Histograma de resíduos série temporal de primavera.



Fonte: Autoria própria (2022).

Figura 28 - Função autocorrelação dos erros de previsão da série temporal de primavera.



Fonte: Autoria própria (2022).

5.3 Previsão da série temporal de verão

O processo de treinamento e teste para previsão desta série seguiram os passos indicados no Capítulo 4. A Tabela 6 apresenta os resultados obtidos utilizando diferentes topologias considerando de 2 a 15 neurônios.

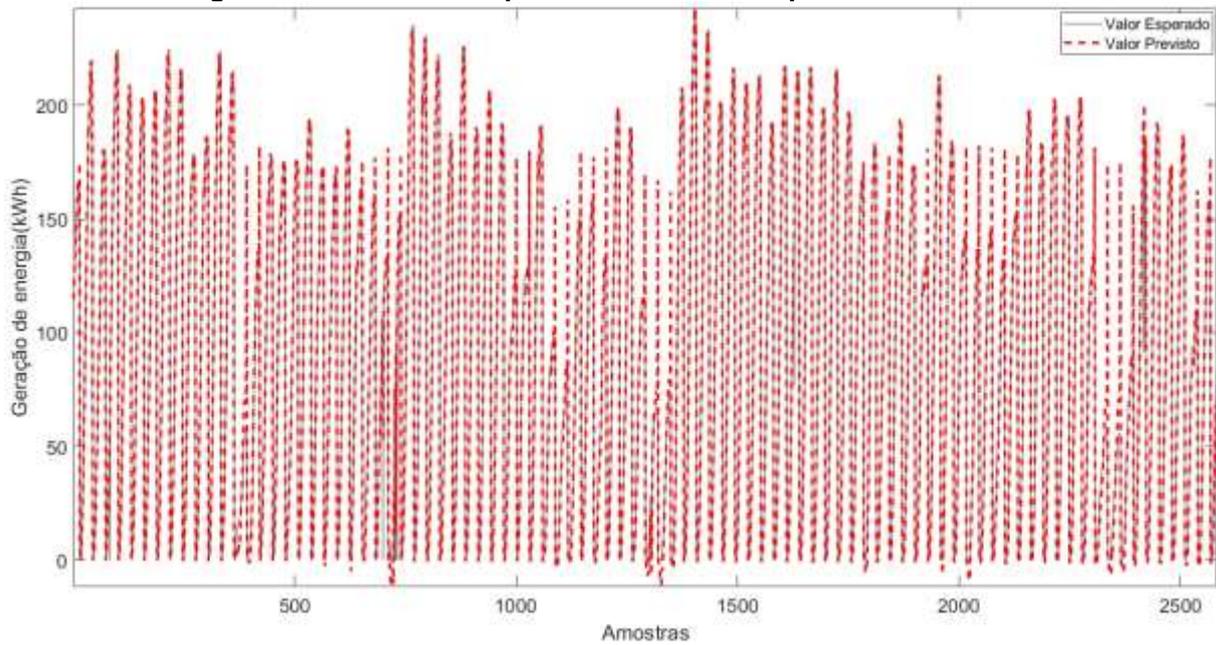
Tabela 6 - Resultados de treinamento e teste da série temporal de verão.

Neurônios na camada oculta	Épocas	Teste	Validação	Treinamento
2	6	0,00278	0,02121	0,00740
3	6	0,00342	0,00871	0,00877
4	6	0,00284	0,00529	0,00902
5	6	0,00259	0,00633	0,00837
6	6	0,00317	0,00980	0,00749
7	6	0,00360	0,00798	0,00778
8	6	0,00369	0,01942	0,00624
9	8	0,00280	0,00835	0,00823
10	6	0,00245	0,01762	0,00674
15	6	0,00160	0,00240	0,00826

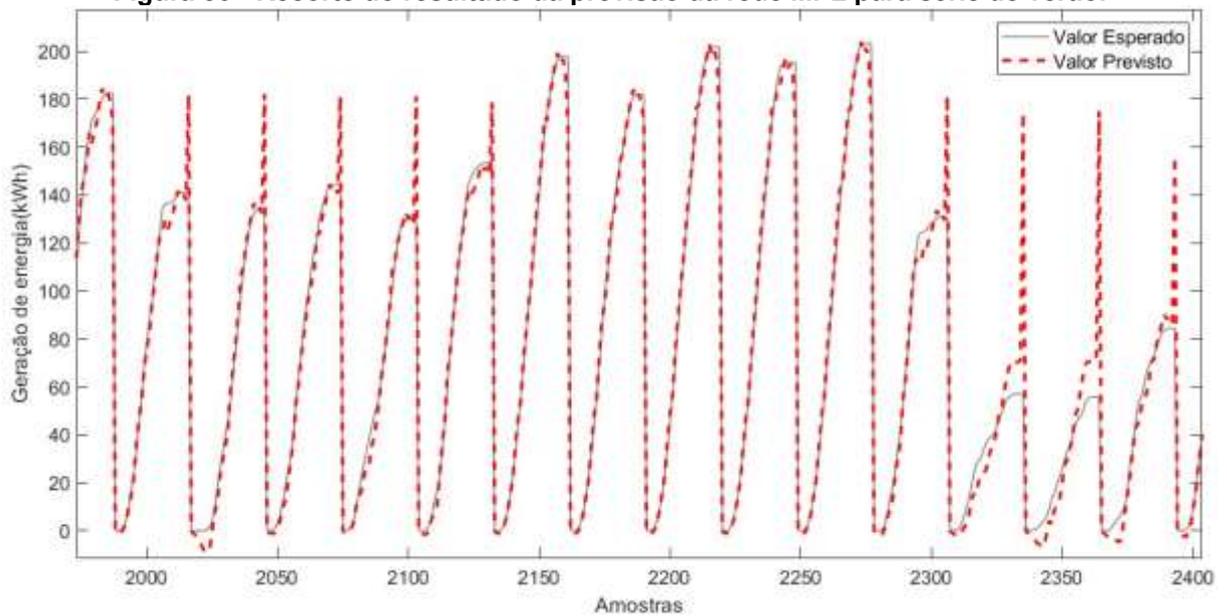
Fonte: Autoria própria (2022).

Dentre os resultados obtidos, a topologia que apresentou maior desempenho durante o processo de teste foi a topologia com 15 neurônios na camada escondida, que corresponde a um MSE de 0,00160. O resultado da previsão da topologia com maior desempenho pode ser visto nas figuras 28, 29, 30, 31 que correspondem aos resultados obtidos na previsão, um recorte com maior resolução dos resultados, histograma de resíduos da previsão e função autocorrelação dos resíduos, respectivamente.

Do ponto de vista computacional, os melhores resultados convergiram na 6ª iteração. Além disso, pode ser observado na Figura 29 que os maiores erros da previsão se manifestaram nos momentos de picos e vales onde ocorreram variações abruptas e os resíduos apresentaram uma média próxima de zero e são descorrelacionados no tempo.

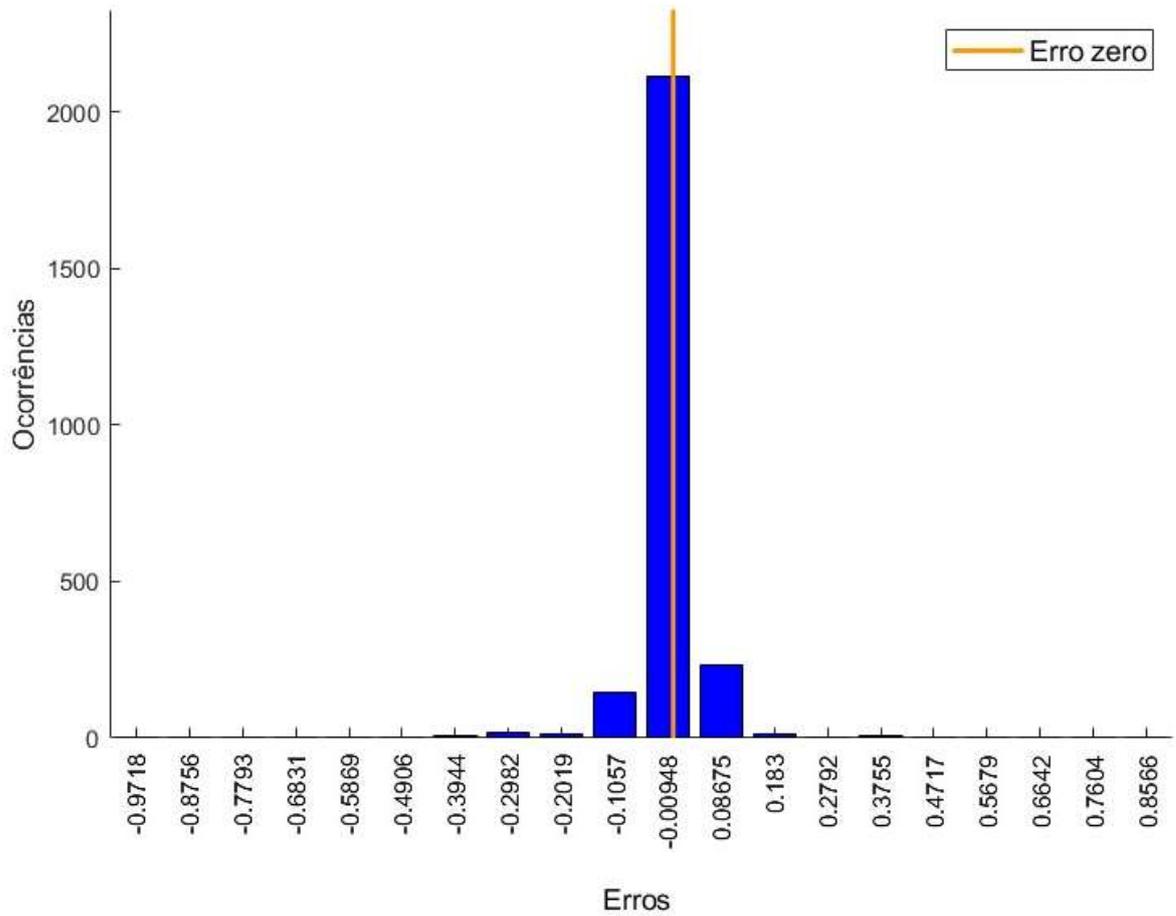
Figura 29 - Resultado da previsão da rede MPL para série de verão.

Fonte: Autoria própria (2022).

Figura 30 - Recorte do resultado da previsão da rede MPL para série de verão.

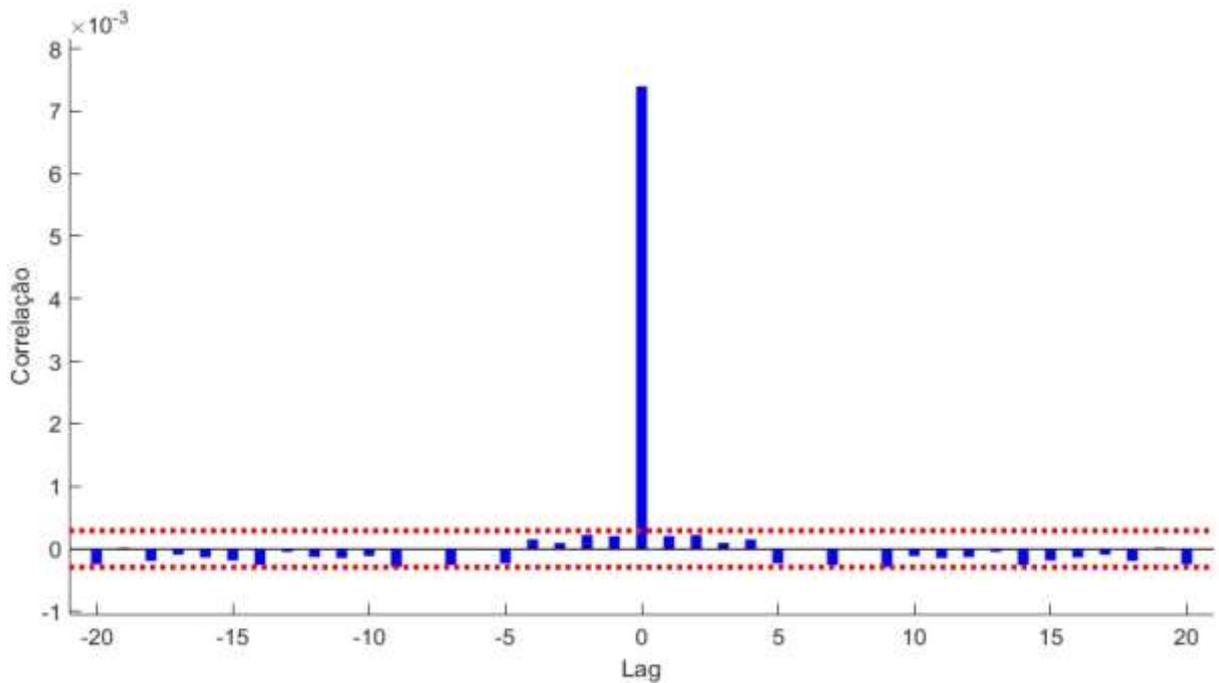
Fonte: Autoria própria (2022).

Figura 31 - Histograma de resíduos série temporal de verão.



Fonte: Autoria própria (2022).

Figura 32 - Função autocorrelação dos erros de previsão da série temporal de verão.



Fonte: Autoria própria (2022).

5.4 Previsão da série temporal de outono

O processo de treinamento e teste para previsão desta série seguiram os passos indicados no Capítulo 4. A Tabela 7 apresenta os resultados obtidos utilizando diferentes topologias considerando de 2 a 15 neurônios.

Tabela 7 - Resultados de treinamento e teste da série temporal de outono.

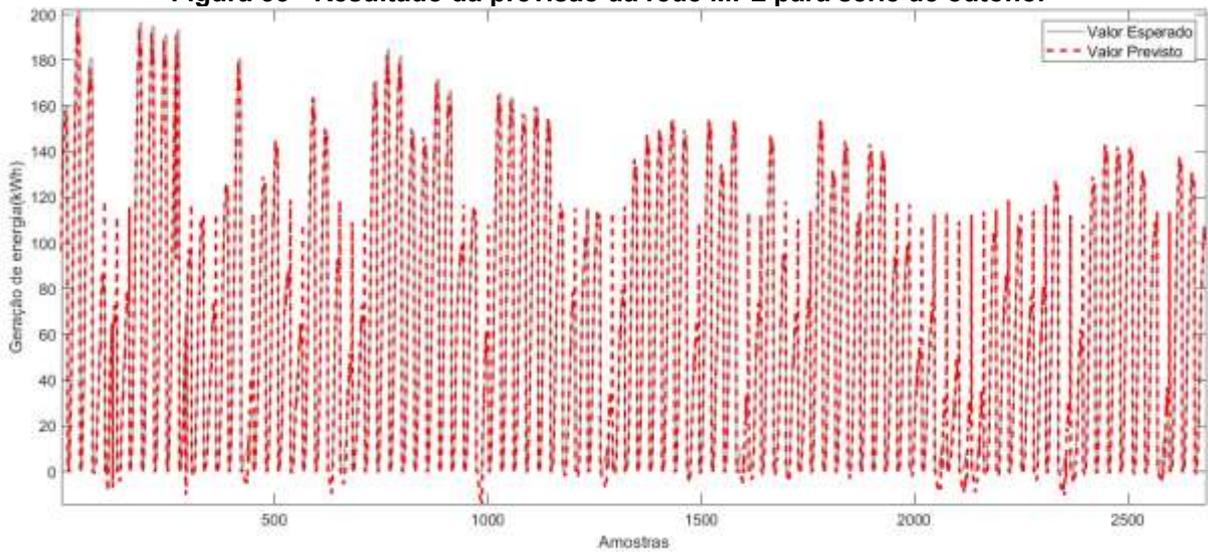
Neurônios na camada oculta	Épocas	Teste	Validação	Treinamento
2	6	0,00613	0,00923	0,01151
3	6	0,00496	0,00991	0,01148
4	13	0,00349	0,01482	0,01019
5	6	0,00529	0,00756	0,01096
6	6	0,00385	0,00806	0,01099
7	6	0,00307	0,01138	0,01077
8	6	0,00342	0,01141	0,01029
9	6	0,00253	0,00725	0,01148
10	6	0,00513	0,02011	0,00954
15	6	0,00349	0,00290	0,01156

Fonte: Autoria própria (2022).

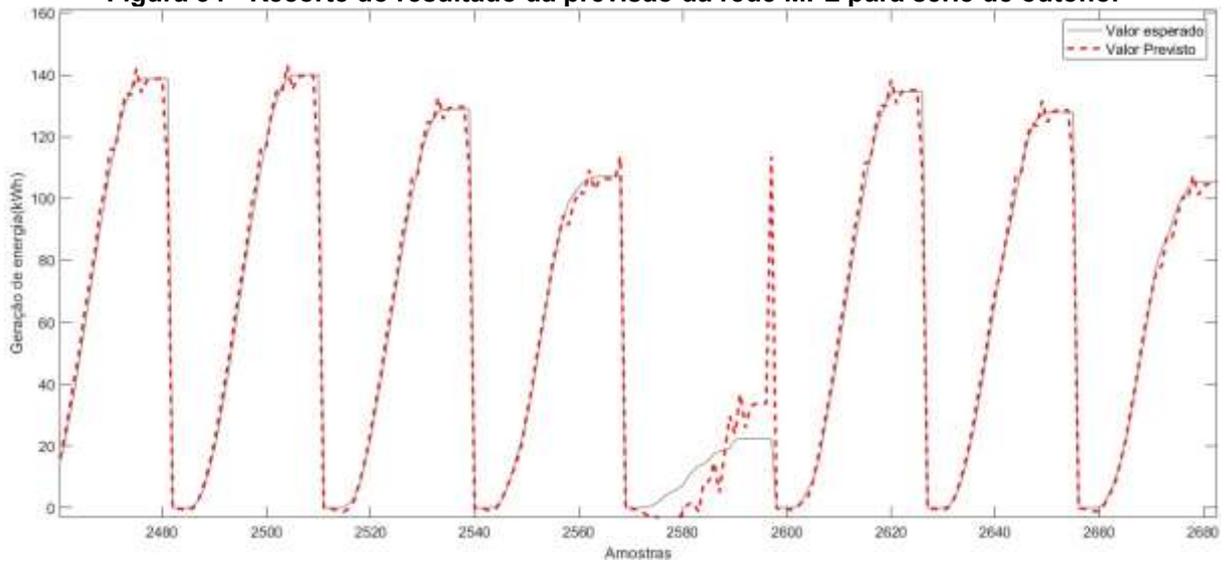
Dentre os resultados obtidos, a topologia que apresentou maior desempenho durante o processo de teste foi a topologia com 9 neurônios na camada escondida, que corresponde a um MSE de 0,00253.

O resultado da previsão da topologia com maior desempenho pode ser visto nas figuras 32, 33, 34, 35 que correspondem aos resultados obtidos na previsão, um recorte com maior resolução dos resultados, histograma de resíduos da previsão e função autocorrelação dos resíduos, respectivamente.

Do ponto de vista computacional, os melhores resultados convergiram na 6ª iteração. Além disso, pode ser observado na Figura 33 que os maiores erros da previsão se manifestaram nos momentos de picos e vales onde ocorreram variações abruptas e resíduos apresentaram uma média próxima de zero e são descorrelacionados no tempo.

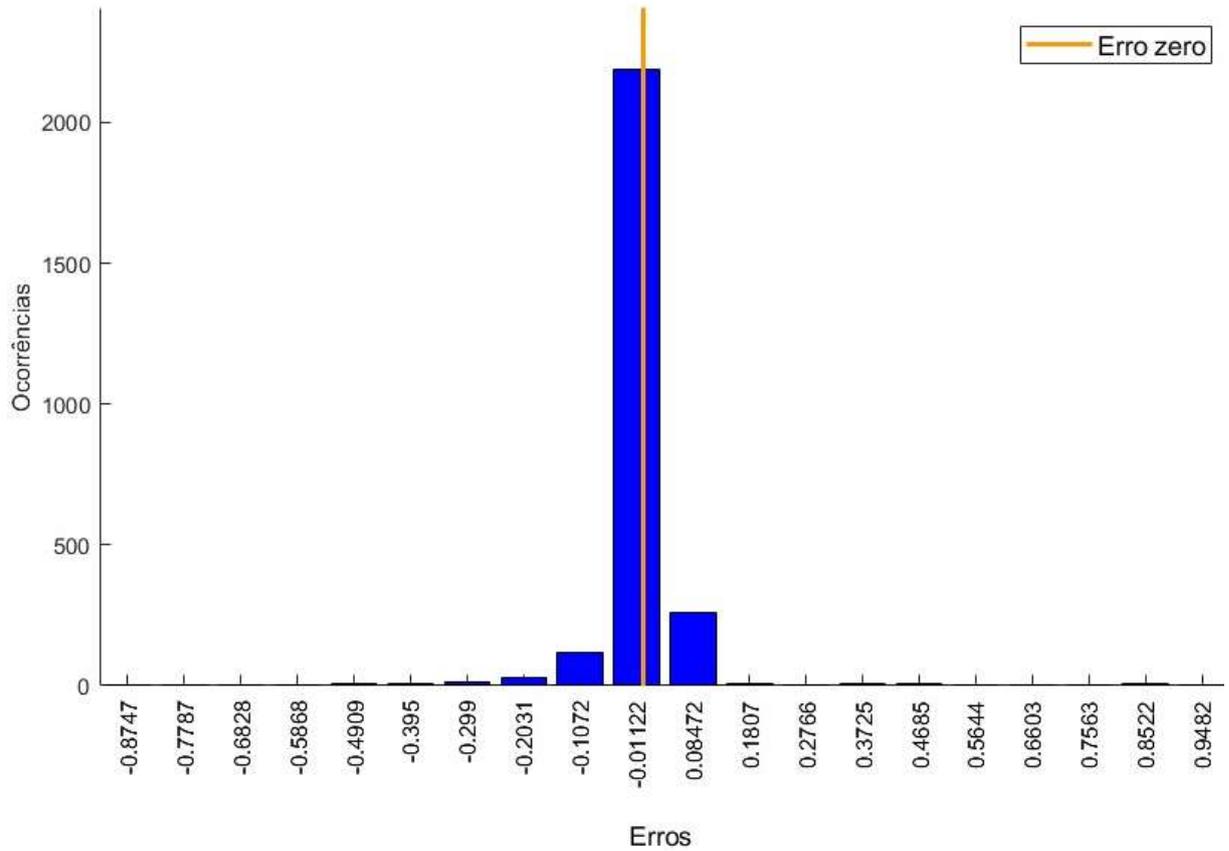
Figura 33 - Resultado da previsão da rede MPL para série de outono.

Fonte: Autoria própria (2022).

Figura 34 - Recorte do resultado da previsão da rede MPL para série de outono.

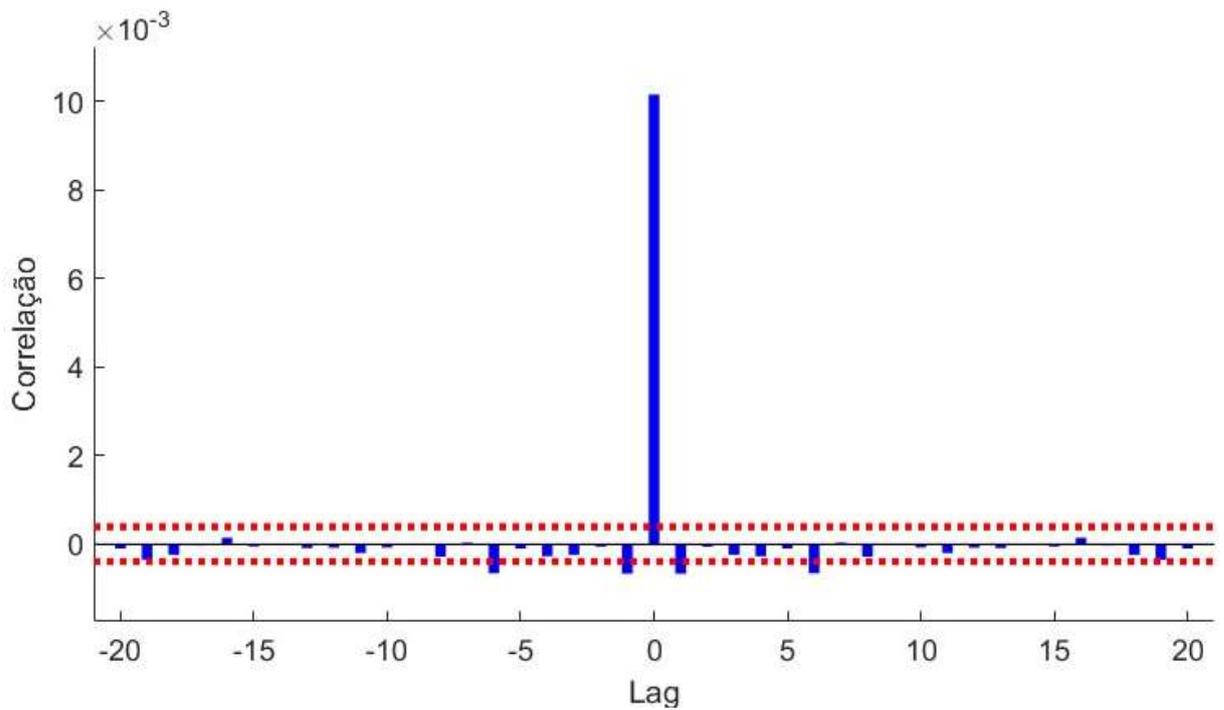
Fonte: Autoria própria (2022).

Figura 35 - Histograma de resíduos série temporal de outono.



Fonte: Autoria própria (2022).

Figura 36 - Função autocorrelação dos erros de previsão da série temporal de outono.



Fonte: Autoria própria (2022).

5.5 Previsão da série temporal sem classificação preliminar

O processo de treinamento e teste para previsão desta série seguiram os passos indicados no Capítulo 4. A Tabela 8 apresenta os resultados obtidos utilizando diferentes topologias considerando de 2 a 15 neurônios.

Tabela 8 - Resultados de treinamento e teste da série temporal sem classificação preliminar.

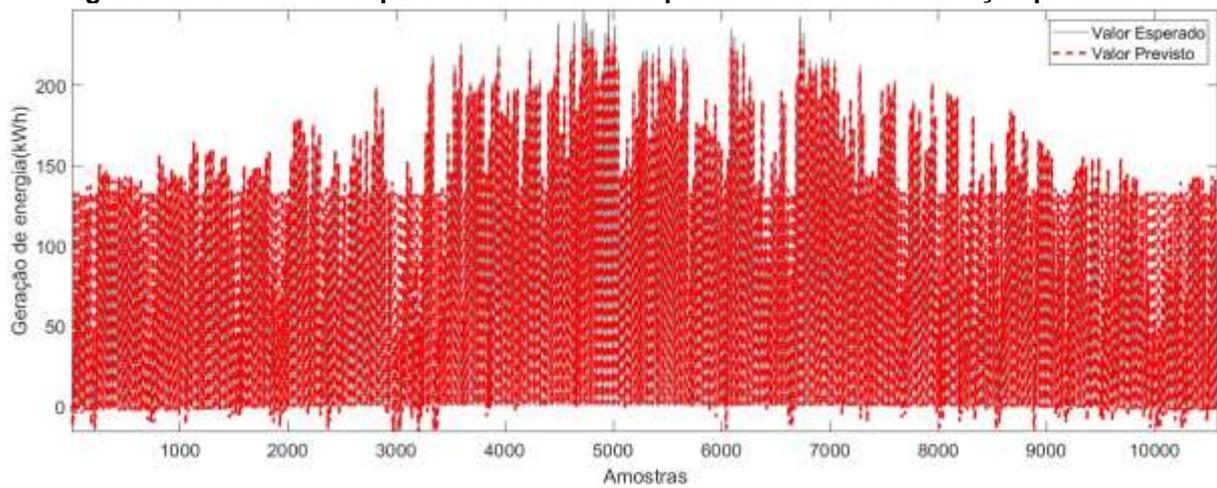
Neurônios na camada oculta	Épocas	Teste	Validação	Treinamento
2	7	0,00970	0,01440	0,01189
3	6	0,00564	0,01172	0,01130
4	6	0,00453	0,01219	0,01046
5	6	0,00703	0,00983	0,01051
6	6	0,00540	0,01779	0,01070
7	6	0,00540	0,00708	0,01097
8	6	0,00565	0,01349	0,01048
9	6	0,00594	0,00845	0,01097
10	6	0,00629	0,01127	0,00987
15	6	0,00620	0,00730	0,00978

Fonte: Autoria própria (2022).

Dentre os resultados obtidos, a topologia que apresentou maior desempenho durante o processo de teste foi a topologia com 4 neurônios na camada escondida, que corresponde a um MSE de 0,00453. O resultado da previsão da topologia com maior desempenho pode ser visto nas figuras 36, 37, 38, 39 que correspondem aos resultados obtidos na previsão, um recorte com maior resolução dos resultados, histograma de resíduos da previsão e função autocorrelação dos resíduos, respectivamente.

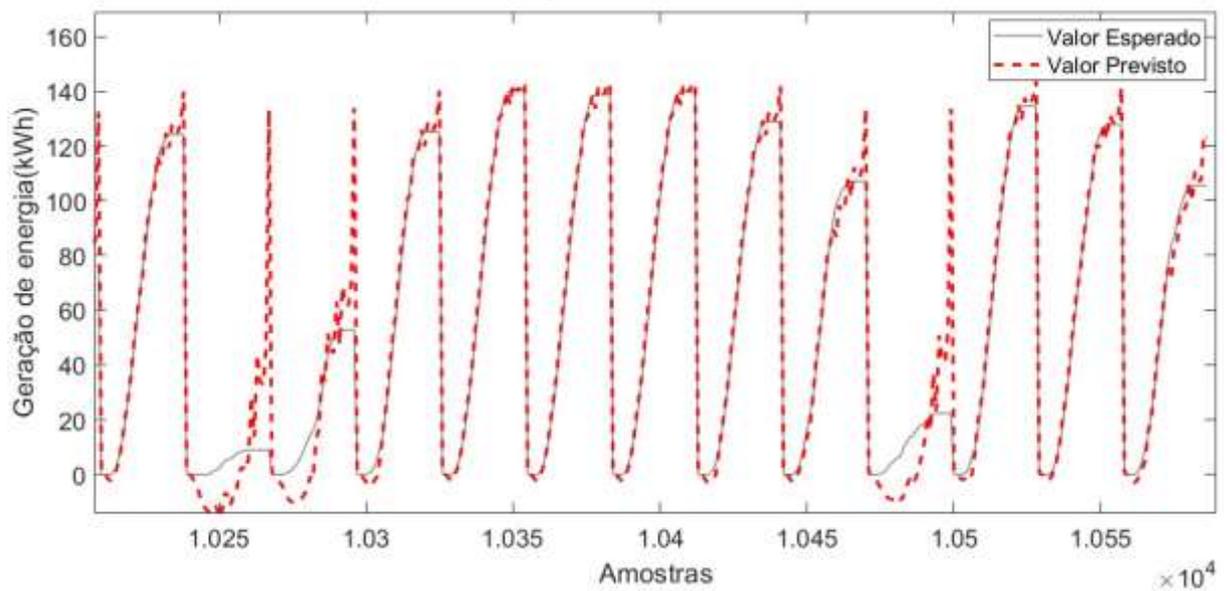
Do ponto de vista computacional, os melhores resultados convergiram na 6ª iteração. Além disso, pode ser observado na Figura 33 que os maiores erros da previsão se manifestaram nos momentos de picos e vales onde ocorreram variações abruptas e resíduos apresentaram uma média próxima de zero e são descorrelacionados no tempo.

Figura 37 - Resultado da previsão da rede MPL para série sem classificação preliminar.



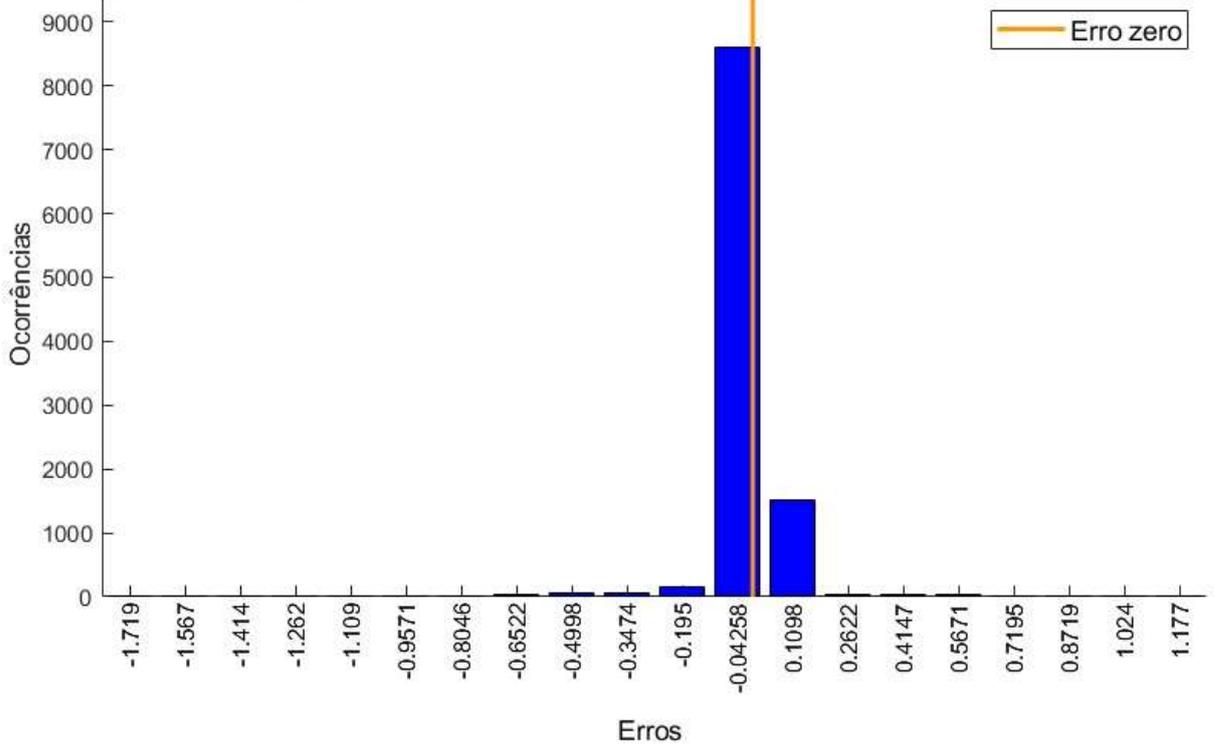
Fonte: Autoria própria (2022).

Figura 38 - - Recorte do resultado da previsão da rede MPL para série sem classificação preliminar.



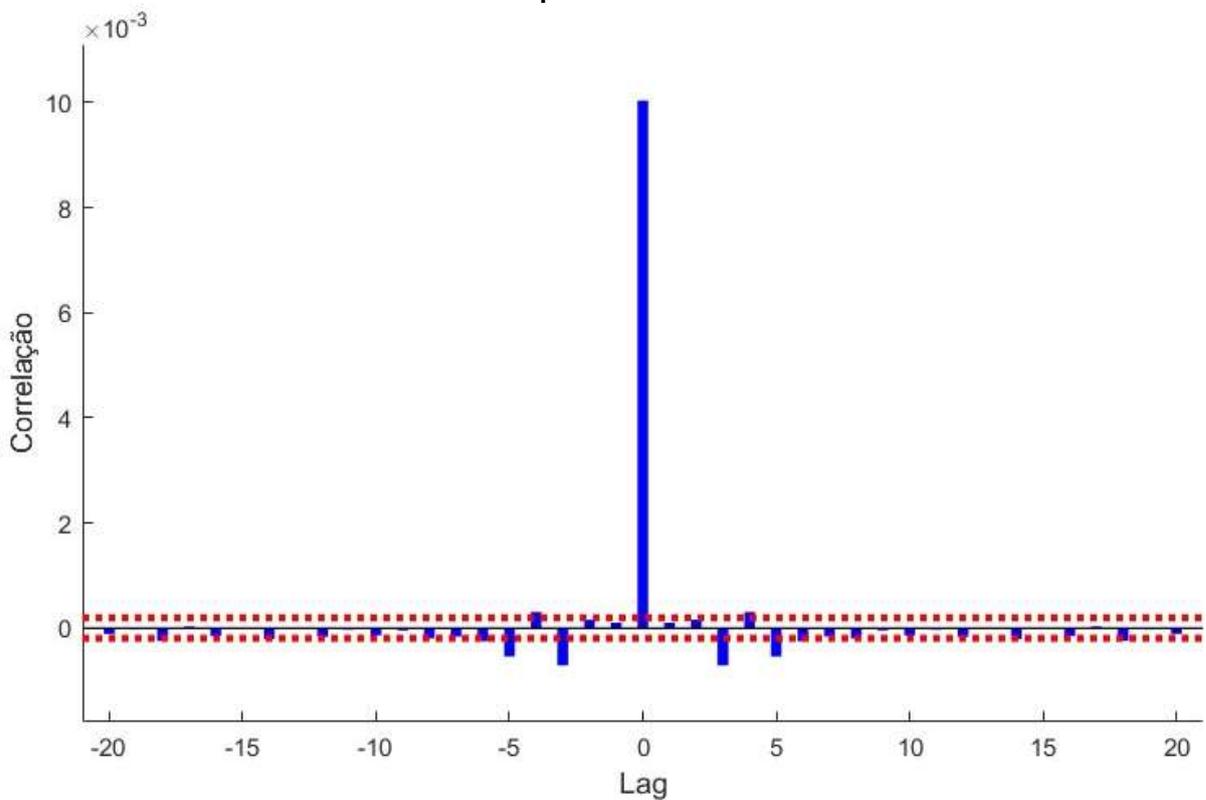
Fonte: Autoria própria (2022).

Figura 39 - Histograma de resíduos série temporal de sem classificação preliminar.



Fonte: Autoria própria (2022).

Figura 40 - Função autocorrelação dos erros de previsão da série temporal sem classificação preliminar.



Fonte: Autoria própria (2022).

5.6 Diagnóstico dos resultados

Esta seção é dedicada a análise dos resultados obtidos nas seções anteriores. A Tabela 9 apresenta o resumo dos melhores resultados obtidos durante a fase de testes das redes neurais artificiais implementada.

Tabela 9 - Resumo dos melhores resultados das previsões.

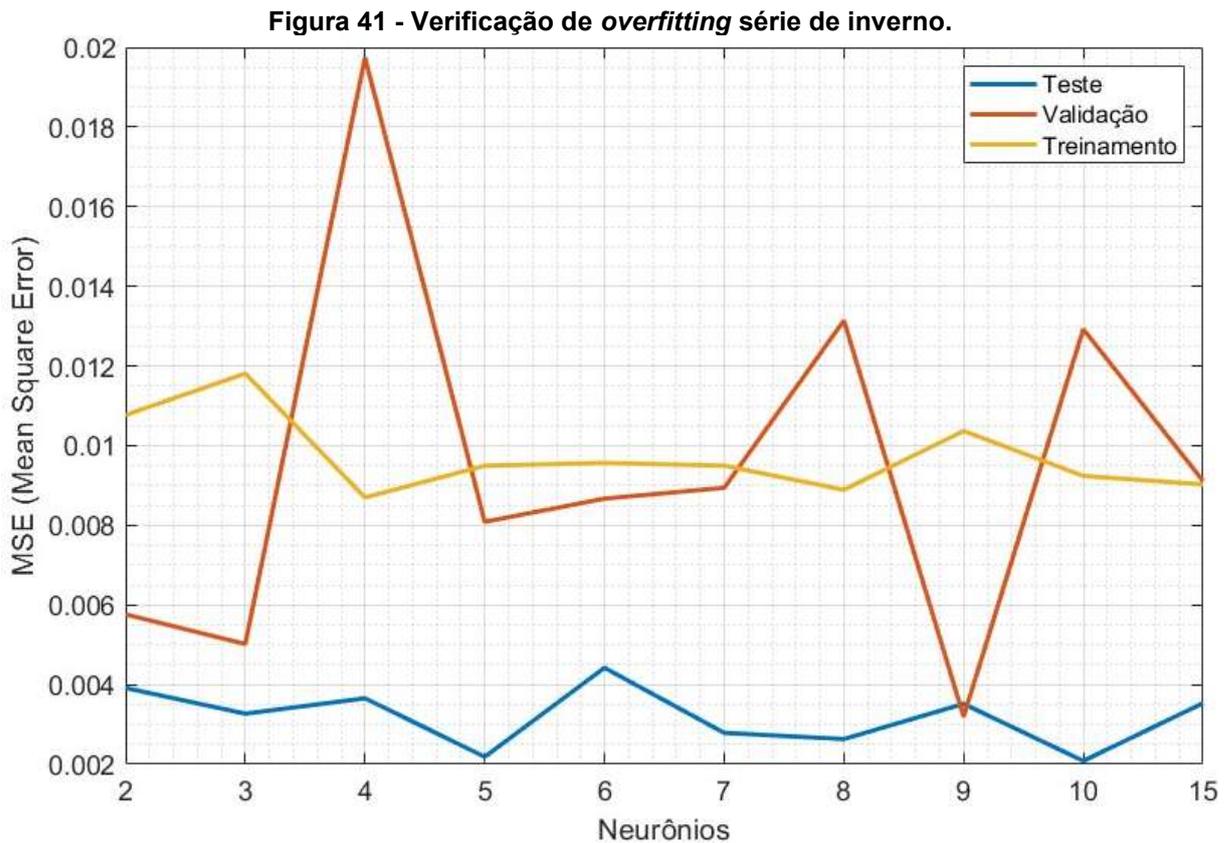
Tipo de série temporal	MSE	Nº de neurônios na camada oculta	Nº de épocas
Sem classificação	0,00453	4	6
Inverno	0,00208	10	6
Primavera	0,00194	7	6
Verão	0,00160	15	6
Outono	0,00253	9	6

Fonte: Autoria própria (2022).

Ao lidar com técnicas de aprendizado de máquina, é conveniente ponderar a precisão do modelo com sua simplicidade, ou seja, o modelo deve usar o menor número possível de parâmetros mantendo o nível de precisão em seus resultados. Num primeiro momento, ao analisar os resultados da fase de teste da previsão, nota-se que as redes com classificação exigiram um número maior de neurônios.

Ao analisar as tabelas 4, 5, 6, 7 e 8 observa-se que à medida que se aumentou o número de neurônios na camada oculta, para alguns casos os resultados na fase de treinamento e testes foram melhores. Isso indica que a rede ainda demonstrava melhoria na capacidade de aprendizado, aprimorando sua capacidade de generalização com o incremento dos neurônios.

Com base nas tabelas 4, 5, 6, 7 e 8, apesar de algumas topologias apresentarem uma quantidade maior de neurônios na camada escondida em relação à previsão sem classificação preliminar, as topologias garantiram um aprendizado sem *overfitting*. O caso anterior foi apresentado na Figura 41, que descreve uma série que teve melhor desempenho com 10 neurônios na camada oculta. Nota-se que ao aumentar o número de neurônios além de 10, a rede apresentou melhores resultados durante a fase de treinamento, porém, os resultados na fase de teste passaram a aumentar. Caso essa curva se mante-se constante à medida que fosse aumentado a quantidade de neurônios, muito provavelmente teria acontecido o fenômeno de *overfitting*.



Fonte: Autoria própria (2022).

Em linha com o esperado, os resultados estão semelhantes aos obtidos por (TAN; DENG, 2017) onde a série temporal de verão apresentou um erro menor comparado com as demais séries que possuem características menos ensolaradas. Contudo, apesar de apresentar erro maior, as demais séries tiveram boa aderência ao modelo de previsão proposto.

De acordo com as figuras 24, 28, 32, 36 e 40, de forma analítica, nota-se que os resíduos não apresentaram um padrão de correlação temporal e segundo o trabalho publicado por (HYNDMAN; ATHANASOPOULOS, 2018) isso indica que os modelos de previsão tiveram uma boa aderência, ou seja, o modelo conseguiu absorver as informações determinísticas e não houve presença de informações estocásticas nos resíduos.

Ainda em relação à análise dos gráficos apresentados nas figuras 21, 25, 29, 33 e 37, a série temporal de inverno foi a série mais aderente ao modelo de previsão de acordo com análise dos resíduos por apresentar resultados concentrados em torno de zero. Da mesma forma, a série de primavera e a série sem classificação preliminar foram as que apresentaram piores resultados em relação à análise resíduos a média ficou mais distante do ponto zero em relação as demais séries.

Entretanto, de maneira geral, apesar dos melhores e piores resultados, a distribuição dos resíduos ficou em torno de um erro zero e de acordo com (TAN; DENG, 2017) confirmam uma boa aderência do modelo de previsão.

A partir da Tabela 8 nota-se que todos os resultados das previsões das redes neurais que foram aplicadas classificação preliminar apresentaram erros inferiores, em relação à previsão da série temporal sem método de classificação preliminar. De forma geral, o melhor resultado da previsão sem classificação preliminar apresentou o dobro do erro quando comparado com o método proposto por este trabalho.

Com base nos resultados, pode-se concluir que todos os modelos de previsão tiveram resultados satisfatórios e em linha com os trabalhos publicados. Além disso, a hipótese de classificação preliminar dos dados de entrada se mostrou superior em relação à sem classificação.

5.7 Contribuições para o campus

As estratégias apresentadas no presente trabalho demonstraram resultados satisfatórios sobre a capacidade de realizar a previsão da potência de saída gerada pela unidade fotovoltaica. Diante disso, o modelo pode se tornar uma ferramenta de auxílio no gerenciamento da energia elétrica gerada no campus.

Este modelo pode ser usado como ferramenta para a planejamento econômico do campus, visto que a planta não dispõe de baterias para armazenamento do excedente gerado, o gestor pode tomar decisões de forma que aumente o consumo por energia elétrica em determinados meses e não gere excedentes para a concessionária, como por exemplo, direcionar eventos para períodos do ano com maior disponibilidade de energia.

Além disso, para períodos de baixa disponibilidade de energia, o gestor pode se preparar financeiramente para gastar uma maior fatia do orçamento com compra de energia elétrica da concessionária, visto que a planta pode não suprir a demanda do campus.

6. CONCLUSÕES

Este trabalho abordou a implementação e comparação de técnicas de previsão utilizando redes neurais artificiais para previsão de geração de energia fotovoltaica de uma planta localizada na Universidade Tecnológica Federal do Paraná, campus Toledo.

A previsão de geração de energia fotovoltaica tem se mostrado importante para o setor elétrico, pois por se tratar de uma fonte de energia intermitente, obter uma previsão com maior grau de precisão se mostra uma ferramenta vantajosa para a gestão e planejamento da sua distribuição desta energia. O objetivo deste trabalho foi desenvolver e comparar os resultados de dois modelos de previsão, um com a rede neural sem pré-processamento algum e outra com série temporal subdivididas em séries temporais de acordo com as estações climáticas.

As estratégias apresentadas no presente trabalho demonstraram resultados satisfatórios sobre a capacidade de realizar a previsão da potência de saída gerada pela unidade fotovoltaica. Apesar das redes classificadas apresentarem melhores resultados com um número maior de neurônios, comparados com a rede sem classificação, isto não foi visto como problema, pois a rede conseguiu extrair informações determinísticas que contribuíram para reduzir o erro da previsão em cerca de 50%, quando comparado com a rede sem classificação preliminar.

Portanto, pode-se concluir que a aplicação das estratégias de previsão abordadas pode servir de uma solução alternativa para produtores de energia fotovoltaica e para as concessionárias de energia elétrica, tornando as operações de gerenciamento mais seguras e efetivas.

REFERÊNCIAS

- ACKERMAN, T.; ET AL. Distributed Generation: a definition. **Electric Power System Research** 57. p. 195–204, 2001.
- AGUIRRE, L. A. et al. Dynamical prediction and pattern mapping in short-term load forecasting. **International Journal of Electrical Power and Energy Systems**, v. 30, n. 1, p. 73–82, jan. 2008.
- ANEEL. **Resolução Normativa n 482 de 17 de abril de 2012**. Aneel, 2012.
- ANTONANZAS, J. et al. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, p. 78–111, 15 out. 2016.
- BALFOUR, J.; SHAW, M.; NASH, N. B. **Introdução ao Projeto de Sistemas Fotovoltaicos**. Rio de Janeiro: LTC, 2016.
- BERQUÓ, D. F.; SOUZA, G. R. DE; FRANÇA, B. W. Impact of Photovoltaic Generation System on the Energy Quality of Distribution Systems. 2018.
- BHATTACHARYA, T.; CHAKRABORTY, A. K.; PAL, K. Effects of Ambient Temperature and Wind Speed on Performance of Monocrystalline Solar Photovoltaic Module in Tripura, India. **Journal of Solar Energy**, v. 2014, p. 1–5, 25 set. 2014.
- CHEN, C. et al. Online 24-h solar power forecasting based on weather type classification using artificial neural network. **Solar Energy**, v. 85, n. 11, p. 2856–2870, nov. 2011.
- DAS, U. K. et al. **Forecasting of photovoltaic power generation and model optimization: A review**. **Renewable and Sustainable Energy Reviews**. Elsevier Ltd. 1 jan. 2018.
- DE GIORGI, M. G.; CONGEDO, P. M.; MALVONI, M. Photovoltaic power forecasting using statistical methods: Impact of weather data. **IET Science, Measurement and Technology**, v. 8, n. 3, p. 90–97, 2014.
- HAGAN, M.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. Em: **IEEE Transactions on Neural Networks**. v. 5p. 989–993.
- HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2001.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. OTexts, 2018.
- LIMA, I.; PINHEIRO, C. A. M.; SANTOS, F. A. O. **Inteligência Artificial**. 1. ed. Rio de Janeiro: Elsevier, 2014.
- LO BRANO, V.; CIULLA, G.; DI FALCO, M. Artificial neural networks to predict the power output of a PV panel. **International Journal of Photoenergy**, v. 2014, 2014.

MATHWORKS. **MATLAB**. 2022.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MINISTÉRIO DE MINAS E ENERGIA. **Boletim Mensal de Monitoramento do Sistema Elétrico Brasileiro**. fev. 2022.

OGLIARI, E. et al. Hybrid predictive models for accurate forecasting in PV systems. **Energies**, v. 6, n. 4, p. 1918–1929, 2013.

PHILIPPI, A. J.; BELICO, L. D. R. **Energia e sustentabilidade**. São Paulo: [2018].

SHI, J. et al. **Forecasting power output of photovoltaic systems based on weather classification and support vector machines**. IEEE Transactions on Industry Applications. **Anais**. 2012.

SHUAI, J. et al. **Carriers transport and electric field distribution in CdS-CdTe ferroelectric-semiconductor coupled solar cell**. 2017 IEEE 44th Photovoltaic Specialist Conference, PVSC 2017. **Anais**. Institute of Electrical and Electronics Engineers Inc., 2017.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia E Ciências Aplicadas. Curso Prático**. Artliber, 2019

TAN, J.; DENG, C. **Ultra-short-term Photovoltaic Generation Forecasting Model Based on Weather Clustering and Markov Chain**. 2017 IEEE 44th Photovoltaic Specialist Conference, PVSC 2017. **Anais**. Institute of Electrical and Electronics Engineers Inc., 2017.

TAN, Y. T. **IMPACT ON THE POWER SYSTEM WITH A LARGE PENETRATION OF PHOTOVOLTAIC GENERATION**. 2004.

UNFCCC. **Intended Nationally Determined Contributions (Philippines)**. p. 1447, 2018.

VIAN ÂNGELO; ET AL. **Energia Solar Fundamentos Tecnologia e Aplicações**. Editora Blucher.

VILLALVA, M. G.; GAZOLI, J. R. **Energia solar fotovoltaica: conceitos e aplicações**. São Paulo: Érica, v. 2, 2012.

WILAMOWSKI, B. M.; YU, H. Levenberg-Marquardt training. Em: **Industrial electronics handbook**. CRC Press, 2018.