UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

MARCOS VINICIUS GRASSI PAMPUCH GABRIEL GONTIJO PIANTINO

PREVISÃO DA IRRADIAÇÃO SOLAR NA CIDADE DE CURITIBA A PARTIR DE REDES NEURAIS ARTIFICIAIS

CURITIBA

2023

MARCOS VINICIUS GRASSI PAMPUCH GABRIEL GONTIJO PIANTINO

PREVISÃO DA IRRADIAÇÃO SOLAR NA CIDADE DE CURITIBA A PARTIR DE REDES NEURAIS ARTIFICIAIS

FORECASTE OF SOLAR IRRADIATION IN THE CITY OF CURITIBA FROM ARTIFICIAL NEURAL NETWORKS

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

Orientador: Prof. Dr. Gerson Máximo Tiepolo

CURITIBA 2023



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

MARCOS VINICIUS GRASSI PAMPUCH GABRIEL GONTIJO PIANTINO

PREVISÃO DA IRRADIAÇÃO SOLAR NA CIDADE DE CURITIBA A PARTIR DE REDES NEURAIS ARTIFICIAIS

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

Data de aprovação: 28/novembro/2023

Gerson Máximo Tiepolo Doutorado Universidade Tecnológica Federal do Paraná

Jair Urbanetz Junior Doutorado Universidade Tecnológica Federal do Paraná

Jorge Assade Leludak Doutorado Universidade Tecnológica Federal do Paraná

> CURITIBA 2023

RESUMO

O objetivo deste trabalho é realizar previsão da irradiação solar na cidade de Curitiba. Ao decorrer do projeto, serão apresentados modelos de previsão de irradiação solar utilizando redes neurais artificiais treinadas pelo banco de dados do Instituto Nacional de Meteorologia (INMET). Essa ideia é uma alternativa para os modelos existentes, os quais, quanto mais preciso se deseja os resultados, maior o números de dados necessários no modelo, resultando um aumento da demanda de processamento. O treinamento das redes neurais, deste trabalho, ocorreu utilizando diferentes grupos de características climáticas subdividas por estações climáticas (verão, outono, inverno e primavera) de forma a verificar quais modelos apresentam melhores previsões. A arquitetura utilizada nas redes neurais se chama feedforward de camadas múltiplas, possuindo para este escopo, duas camadas ocultas. Como parâmetros internos aos modelos, são aplicadas funções de ativação Sigmoidais nas camadas ocultas e funções Lineares Retificadas na camada de saída. A otimização dos pesos é feito pelo algoritmo Stochastic gradient descent. Como fruto desse treinamento nos diferentes cenários, o *dataset 4* foi o que melhor performou na previsão de irradiação no período do verão, já o dataset 5, teve os menores erros no outono, no inverno e na primavera. Portanto, a estratégia de separação do banco de dados inicial entre estações mostrou-se eficiente, resultando em erros variados para as diferentes estações. O melhor resultado obtido, foi um erro de 124,93 Wh/m^2 , através do dataset 5 treinado com dados do inverno, pelo cálculo de erro MAE e o maior erro obtido foi de 246,71 Wh/m^2 , na primavera pelo dataset 2, pelo erro RMSE, mostrando uma grande variação no erro conforme os dados escolhidos para o treinamento.

Palavras-chave: irradiação solar; rede neural artificial; base de dados; previsão.

ABSTRACT

The main goal in this work is make the forecast about solar irradiation in the city of Curitiba. Along this work, will be introduced forecast solar irradiation models using artificial neural networks trained by the dataset of Instituto Nacional de Meteorologia (INMET). This idea is an alternative for the existent models, which, the more accurate the results are desired, bigger the number os data necessary for the model, resulting an increase in processing demand. The training of the neural networks in this work happen using different groups of climatic characteristics subdivided by seasons climatic (summer, fall, winter and spring) to verify which one present the best forecast. The architecture used in this neural networks is named feedforward multilayer with two hidden layers. As internal parameters to the models, Sigmoidal activation functions are applied to the hidden layers and Rectified Linear functions in the output layer. The weight optimization is done by the Stochastic gradient descent algotithm. As a result of these trainings using different features, the dataset 4 perform better in the forecast of irradiation in the summer and the dataset 5 had lower erros in fall, winter and spring. Therefore, the split made between the seasons show more efficiency resulting in minor errors for each different setting. The best result, was a error of 124,93 Wh/m^2 in the winter for the dataset 5, by MAE and the biggest global error was 246,71 Wh/m^2 , in the spring for the setting dataset 2, by RMSE, showing very different results depending of the dataset used for training.

Keywords: solar irradiation; artificial neural network; dataset; forecast.

LISTA DE FIGURAS

Figura 1 – Expansão em energia da micro e mini geração distribuída	12
Figura 2 – Processo de interação da radiação solar com os principais constituin-	
tes atmosféricos	16
Figura 3 – Componentes da irradiância solar	16
Figura 4 – Estação meteorológica automática Araçuaí A566	18
Figura 5 – Topologia de uma rede neural artificial com camada oculta	21
Figura 6 – Modelo de um neurônio artificial de McCulloch e Pitts	21
Figura 7 – Função Heaviside	23
Figura 8 – Função Linear	24
Figura 9 – Função Sigmoidal	24
Figura 10 – Gráfico da representação da Função Retificada Linerar	25
Figura 11 – Rede feedforward de camada simples	26
Figura 12 – Rede feedforward de múltiplas camadas com backpropagation	27
Figura 13 – Otimização de um parâmetro por gradiente descendente genérico	30
Figura 14 – Plotagem função de perda versus quantidade de interações no SGD	31
Figura 15 – Etapas para a aplicação de uma base de dados	33
Figura 16 – Dados medidos pelo INMET na estação Curitiba A807	34
Figura 17 – Dia com ausência de dados medidos na estação A807	35
Figura 18 – Dados medidos na estação Curitiba A807	37
Figura 19 – Representação da RNA para estimar a irradiação	38
Figura 20 – Matriz de correlação <i>dataset</i> 1	43
Figura 21 – Matriz de correlação <i>dataset</i> 2	44
Figura 22 – Matriz de correlação <i>dataset</i> 3	45
Figura 23 – Matriz de correlação <i>dataset</i> 4	46
Figura 24 – Matriz de correlação <i>dataset</i> 5	47
Figura 25 – Gráfico loss function do dataset 5 para as estações: (a) Verão, (b) Ou-	
tono, (c) Inverno e (d) Primavera	48
Figura 26 – Erros RMSE agrupados por estação	51

LISTA DE TABELAS

Tabela 1 –	Média móvel ponderada com 5 medidas	39
Tabela 2 –	Média móvel ponderada com 10 medidas	39
Tabela 3 –	Média móvel ponderada com 15 medidas	39
Tabela 4 –	Composição dos <i>datasets</i>	40
Tabela 5 –	Erro na previsão da irradiação solar em Curitiba	49
Tabela 6 –	Modelo com menor RMSE de Validação	50

LISTA DE ABREVIATURAS E SIGLAS

Siglas

CO_2	Dióxido de Carbono
O_3	Ozônio
BGD	Batch Gradient Descent
EMA's	Estações Meteorológicas Automáticas
EPE	Empresa de Pesquisa Energética
INMET	Instituto Nacional de Meteorologia
LABENS	Laboratório de Energia Solar
LM	Levenberg-Marquardt
MAE	Erro Médio Absoluto
mBGD	Mini-Batch Gradient Descent
RMSE	Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial
SGD	Stochastic Gradient Descent
SIN	Sistema Interligado Nacional
UFSCar	Universidade Federal de São Carlos
UTC	Tempo Universal Coordenado

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Tema	10
1.1.1	Delimitação do tema	10
1.2	Problemas e premissas	10
1.3	Objetivos	11
1.3.1	Objetivo geral	11
1.3.2	Objetivos específicos	11
1.4	Justificativa	12
1.5	Procedimentos metodológicos	13
1.6	Estrutura do trabalho	14
2	FUNDAMENTAÇÃO TEÓRICO	15
2.1	A radiação e a irradiação solar	15
2.2	Estações de medição da radiação solar	17
2.2.1	Estações meteorológicas automáticas do Instituto Nacional de Meteorologia.	17
2.3	Redes neurais artificiais	18
2.3.1	Evolução das redes neurais artificiais	18
2.3.2	Funcionamento de uma rede neural artificial	20
2.3.2.1	Composição base da rede neural	20
2.3.2.2	Diferentes funções de ativação do neurônio	23
2.4	Arquiteturas de redes neurais artificiais	25
2.4.1	Arquitetura <i>feedforward</i> (alimentação à frente) de camada simples	26
2.4.2	Arquitetura <i>feedforward</i> (alimentação à frente) de múltiplas camadas	27
2.5	Algoritmos de otimização	28
2.5.1	Gradient descendent method	29
2.5.2	Gradiente descendente estocástico	30
2.5.3	Levenberg-Marquardt method	31
2.6	Redes neurais regressivas médias	32
3	METODOLOGIA E DESENVOLVIMENTO	33
3.1	Aquisição dos dados	33
3.2	Processamento dos dados	34

3.3	Configuração dos cenários	37
3.3.1	Modelagem usando lag (Atraso)	37
3.3.2	Modelagem usando médias móveis ponderadas	38
3.3.3	Composição dos testes	40
3.3.4	Parametrização	41
4	RESULTADOS	43
4.1	Correlação das variáveis dos <i>datasets</i>	43
4.2	Aplicação dos cenários propostos	47
4.3	Discussão dos resultados obtidos	49
5	CONCLUSÃO	53
5.1	Dificuldades encontradas no decorrer do estudo	54
5.2	Possíveis desenvolvimentos futuro	55
	REFERÊNCIAS	56

1 INTRODUÇÃO

1.1 Tema

Atualmente, com o aquecimento da atmosfera, o meio ambiente vem sofrendo alterações que podem ser percebidas como a alteração nos regimes das chuvas, o aumento do número de furacões, elevação do nível dos oceanos, maior frequência de novos recordes de calor, intensificação das ondas de calor extremo, entre outros. Essas alterações também estão interferindo no clima das regiões do planeta, tornando cada vez mais difícil a realização da previsão do tempo (MARQUES, 2022).

Para se realizar a previsão do tempo, são necessários vários dados e quanto mais preciso se deseja a previsão, mais dados climáticos são necessários para serem utilizados em seus modelos, provocando o aumento na demanda de processamento (ANOCHI; SILVA, 2009).

Uma maneira precisa e recente de se realizar previsões do tempo de forma concisa, é através da utilização de redes neurais modernas.

De forma sucinta, em uma rede neural, escolhe-se algumas variáveis para serem os dados de entrada no sistema e a resposta desejada na saída do mesmo. Essas variáveis de entrada podem ser, por exemplo, temperatura do ar, velocidade do vento, umidade relativa do ar, entre outras. Este conjunto de dados é denominado *dataset* (LORBACH *et al.*, 2018).

Cabe ressaltar que, neste estudo, foi utilizado como resposta desejada do sistema as irradiações solares medidas.

O processo de treinamento se inicia com uma parte do *dataset* alimentando a rede neural com variáveis de entrada e aprendendo com os erros nas predições gerados pela comparação do resultado de saída com o seu "gabarito" (LORBACH *et al.*, 2018).

Com um modelo bem treinado, é possível, por exemplo, estimar os valores de irradiação solar na cidade de Curitiba para os meses seguintes e consequentemente, realizar uma previsão da quantidade de energia elétrica que será possível gerar em um futuro à médio prazo.

1.1.1 Delimitação do tema

A partir de diferentes grupos de dados formados a partir de uma fonte de dados e segregados por estação, foram construídas e avaliadas entre si, algumas redes neurais capazes de prever os valores de irradiação solar na cidade de Curitiba no Paraná.

1.2 Problemas e premissas

Para possibilitar o treinamento do modelo de inteligência artificial, é necessário uma quantidade expressiva de dados climáticos, os quais são usados no treinamento e na validação dos resultados do modelo. Com um aumento do volume de dados, mais poder computacional é demandado para as previsões temporais (ANOCHI; SILVA, 2009).

Para realização das previsões e das validações, foi necessário a utilização dos dados do INMET os quais são, em suma, coletados por hora durante todos os dias do ano.

Cabe ressaltar que, mesmo utilizando um grande número de dados, é previsto que as respostas finais encontradas pela rede neural apresentem um erro. Esta divergência entre o valor previsto e o real pode inviabilizar a utilização dos modelos em aplicações que demandam um grau de precisão muito elevado em sua predição.

1.3 Objetivos

A partir de um conjunto de redes neurais treinadas individualmente, almeja-se tanto analisar seus resultados e erros de previsão para cada estação do ano, quanto comparar qual conjunto de dados, criado a partir dos dados do INMET, produziu o melhor resultado.

Além disso, cabe a essa rede neural auxiliar à prever a irradiação solar na cidade de Curitiba nos próximos meses e demonstrar se sua margem de erro permitiu previsões concisas dado o clima adverso da cidade de Curitiba.

1.3.1 Objetivo geral

Selecionar, treinar e aperfeiçoar todos os componentes de um conjunto de redes neurais artificiais separadas por estação do ano de modo que elas possam estimar os valores de irradiação solar na cidade de Curitiba com o menor erro possível.

1.3.2 Objetivos específicos

- Selecionar o modelo de rede neural e as variáveis climáticas a ser inicialmente utilizadas;
- 2. Filtrar os dados e modelar os *datasets*, os quais são injetados nas entradas das redes neurais artificiais;
- Treinar os modelos de modo que os mesmos estimem a irradiação solar na cidade de Curitiba-PR em diferentes datas;
- 4. Calcular as margens de erro das predições dos modelos;
- Testar diferentes configurações dos modelos e verificar qual retorna os melhores resultados;

 Analisar os resultados finais obtidos em cada modelo de forma a concluir qual dos datasets foi mais efetivo na previsão de cada estação do ano;

1.4 Justificativa

Atualmente, observa-se um movimento de expansão da geração fotovoltaica distribuída. Segundo a Empresa de Pesquisa Energética (EPE) (2022), serão instalados no Sistema Interligado Nacional (SIN) cerca de 37 GW de potência entre os anos de 2021 e 2031. A partir dessa estimativa, serão instalados anualmente uma média de 7,1 GWméd, da qual, 93% advém da geração fotovoltaica, como se observa na Figura 1.



Figura 1 – Expansão em energia da micro e mini geração distribuída

Com um aumento na geração fotovoltaica, observa-se cotidianamente a necessidade de instrumentos de medição e de previsão de variáveis climáticas cada vez mais precisos de modo a possibilitar uma melhor aplicação das tecnologias na região.

Usando dados anteriores e variáveis genéricas, é possível constatar por meio de predições de base, como serão os valores futuros de diversos aspectos climáticos, como a irradiação solar, a temperatura do ar, a velocidade dos ventos, os horários de chuva, entre outros. Apesar destas previsões serem benéficas para diversas aplicações, elas são muitas vezes genéricas devido a tecnologia que usam e também porque deixam de levar em conta características únicas e fundamentais da cidade que está sendo analisada.

Com os avanços promissores da aplicação de modelos de inteligência artificial em diversas áreas da sociedade, estudos de previsões robustas em pontos específicos do mapa foram desenvolvidos usando esta tecnologia.

Como exemplo de estudo, tem-se o trabalho acadêmico elaborado por Carvalho, Laboissiere e Fernandes (2021) da Universidade Federal de São Carlos (UFSCar), onde observa-se a aplicação de uma rede neural utilizando dados do Instituto Nacional de Meteorologia para prever a irradiação solar e a temperatura do ar na cidade de São Luís, no Maranhão (CARVALHO; LABOISSIERE; FERNANDES, 2021).

Portanto, justifica-se este estudo como uma oportunidade para a simulação e previsão dos cenários de incidência de irradiação solar na cidade de Curitiba ao longo das estações

do ano usando como base, modelos de inteligência artificial difundidos no meio acadêmico e comercial.

1.5 Procedimentos metodológicos

A teoria deste trabalho foi embasada por meio de artigos técnico-científicos, dissertações, teses, sites da internet, além de livros técnicos, cujo tema abordado foi o desenvolvimento e a configuração de redes neurais de forma a gerar previsões assertivas acerca da irradiação solar na cidade de Curitiba e posteriormente um estudo da acurácia dos resultados obtidos com base em valores reais da cidade de Curitiba.

Essa pesquisa pode ser classificada quanto à natureza como uma pesquisa aplicada e de propósito fechado. Inicialmente, foi realizado um estudo detalhado do funcionamento das redes neurais. Também foi estudada a temática de modelos matemáticos e técnicas de inteligência artificial aplicadas em predições regressivas (valores numéricos). Em seguida, foi realizado um levantamento dos dados necessários para o treinamento do modelo e qual fonte foi usada para obtê-los. Algumas variáveis a serem estudadas quanto a sua pertinência serão:

- Temperatura mínima;
- Temperatura máxima;
- · Temperatura do ar;
- Irradiação solar;
- Umidade relativa do ar;
- Pressão atmosférica;
- Velocidade do vento;
- · Chuva acumulada;

Com a escolha das variáveis, foi analisado a necessidade de tratamento das mesmas. Finalmente, foram definidos vários *datasets* diferentes para o treinamento da rede neural escolhida. Seus resultados foram então avaliados tanto individualmente quanto em conjunto entre si.

É importante salientar que apesar da ordem definida anteriormente ser a lógica principal a ser seguida, a área de treinamento de modelos de inteligência artificial se condensa muito em tentativas empíricas com diferentes variáveis de modo a encontrar a que melhor performar nos resultados. Tendo isso em mente, é considerado recorrente a necessidade de retornar à um procedimento anterior para refinar ou mudar seu conteúdo de modo a melhorar os resultados dos passos seguintes.

1.6 Estrutura do trabalho

A estrutura do trabalho é dividida em cinco capítulos onde o primeiro capítulo apresentará uma breve introdução acerca dos desafios do modelo atual na previsão do tempo e da irradiação solar e a possibilidade da utilização das redes neurais artificiais neste meio. Também foram abordados os limites e as dificuldades para se obter um resultado satisfatório, os principais objetivos do trabalho, os motivos para a realização desse estudo e o modo como o mesmo será guiado.

O segundo capítulo, por sua vez, tratará de uma revisão bibliográfica sobre o detalhamento dos temas estudados, e portanto, foi organizada em seis seções. Na primeira seção, são apresentados os conceitos básicos de radiação solar e irradiação solar. Na sequência, a segunda seção deste capítulo, abordará as estações de medição de irradiação solar com enfoque nas estações meteorológicas automáticas do Instituto Nacional de Meteorologia. A terceira seção explicará a evolução e o funcionamento base das redes neurais artificiais e a quarta abordará a arquitetura base de uma rede neural moderna. Na quinta seção, será apresentado os algoritmos de otimização utilizados no aprendizado, com ênfase nos métodos *gradient descendent method*, gradiente descendente estocástico e *Levenberg-Marquardt method*. Para finalizar, será apresentado a configuração da rede neural aplicada no trabalho.

No terceiro capítulo, serão apresentadas a aquisição dos dados, processamento e tratamento que estes dados passaram. Além disso, também será explicado dois métodos para a elaboração dos diferentes *datasets* e a descrição dos mesmos.

Por fim, no quarto capítulo deste trabalho, será mostrado os resultados do treinamento dos cenários propostos e a discussão dos resultados obtidos e, posteriormente, no quinto capítulo, será apresentado as conclusões referentes ao estudo realizado, dificuldades encontradas no decorrer do estudo e possíveis desenvolvimentos futuro.

2 FUNDAMENTAÇÃO TEÓRICO

Neste capítulo estão relacionados os fundamentos conceituais que baseiam a análise dos fenômenos sob estudo obtidos a partir do estudo das referências bibliográficas.

Primeiramente, será discutido acerca dos índices de radiação solar e irradiação solar, que são métricas importantes para entender o motivo de se utilizar uma Rede Neural Artificial (RNA), para prevê-las.

Posteriormente, será apresentado um modelo de estação de onde é possível obter os índices de irradiação solar em determinadas áreas. Sendo esta, a estação meteorológica automática do INMET.

Na sequência, os principais conceitos envolvendo a área de redes neurais artificiais será explicado. Iniciando-se pela evolução dessa área, seguindo para a explicação das estruturas que compõem uma RNA. Nesta explicação, será dado ênfase ao funcionamento de uma RNA.

A partir disso, a arquitetura de *multilayer Perceptron* é apresentada, sendo está, a arquitetura mais aconselhável no cálculo da previsão da irradiação solar na cidade de Curitiba.

Por fim, os principais algoritmos de otimização e seu funcionamento são descritos ao final do capítulo, assim como seus principais pontos positivos e negativos. Os algoritmos a serem apresentados serão *gradient descendent method*, gradiente descendente estocástico e o *Levenberg-Marquardt method*.

2.1 A radiação e a irradiação solar

A radiação proveniente do sol é a fonte energética de maior importância na conjuntura de processos físicos, químicos e biológicos terrestres segundo Silva *et al.* (2010). A radiação solar, a qual é responsável por 99,9% da energia térmica do planeta, é direcionada para diversas partes do ecossistema terrestre como a atmosfera, os continentes e os oceanos (CARVALHO; LABOISSIERE; FERNANDES, 2021).

A definição normativa da radiação solar é tratada como a transferência de energia vinda do sol através da propagação de ondas eletromagnéticas, já o conceito de irradiação solar, corresponde a radiação solar integrada durante um dia inteiro e tem como unidade, watt hora por metro quadrado Wh/m ou J/m^2 (ABNT, 2006).

Além de depender de variáveis climáticas como a umidade relativa do ar e a nebulosidade, a intensidade da radiação em uma região também está diretamente atrelada às coordenadas da mesma, ao horário e ao dia do ano em que a medição foi efetuada (BAPTISTA, 2016). A Figura 2 ilustra o processo de penetração da radiação solar na Terra. Nele, dentre os 50% da irradiação que atinge a superfície terrestre, 45% é absorvido e 5% é refletido novamente de volta ao espaço (PEREIRA *et al.*, 2017).



Figura 2 – Processo de interação da radiação solar com os principais constituintes atmosféricos

Fonte: PEREIRA et al. (2017).

Mesmo assim, estima-se que 1.5×10^{18} kWh de energia solar chegam anualmente a Terra. Esse montante de energia corresponde a um valor da ordem de 10 mil vezes o consumo energético mundial no ano de 2004 (PINHO; GALDINO, 2014).

A atmosfera global é constituída de diversos gases atmosféricos e aerossóis. Na fração sem vapor de água da atmosfera, a composição majoritária corresponde a 99% de oxigênio e nitrogênio, e 1% de argônio e outros gases. Também observa-se a presença em pequenas quantidades, dos gases Dióxido de Carbono (CO_2) e Ozônio (O_3), ambos de extrema importância nos processos radiativos (PEREIRA *et al.*, 2017).



Figura 3 – Componentes da irradiância solar

Fonte: PEREIRA et al. (2017).

Considerando a radiação solar incidente sobre uma superfície receptora, esta é subdividida em componente direta, componente difusa, e em alguns casos, componente "albedo". Sendo a radiação direta aquela proveniente diretamente do sol, ela depende fortemente da quantidade de nuvens presentes no céu, podendo ser nula em dias completamente nublados (PINHO; GALDINO, 2014).

A radiação difusa é aquela que atinge o solo após a reflexão dos raios pela atmosfera. Já a componente albedo, só acontece quando existe a reflexão dos raios que já se encontram na superfície terrestre por parte de fatores presentes no ambiente como o solo, a vegetação, os terrenos diversos, etc. (PINHO; GALDINO, 2014).

A Figura 3 ilustra as diferentes componentes existentes sobre uma superfície receptora e a soma de todas as componentes sobre um determinado ponto é denominada de radiação global.

2.2 Estações de medição da radiação solar

No Brasil, existem atualmente grupos de medição de variáveis meteorológicas advindos de projetos, iniciativas e tecnologias diferentes.

Cabe ressaltar, quanto a sua pertinência a nível nacional, a existência das Estações Meteorológicas Automáticas (EMA's) do Instituto Nacional de Meteorologia (INMET) e também, de forma complementar, a nível regional no Paraná, as estações solarimétricas implantadas e mantidas pelo Laboratório de Energia Solar (LABENS) da Universidade Tecnológica Federal do Paraná (UTFPR). Para fins de aplicação, apenas as estações do INMET foram aprofundadas no trabalho.

2.2.1 Estações meteorológicas automáticas do Instituto Nacional de Meteorologia

Um exemplo típico desse tipo de estação meteorológica automática real pode ser visto na Figura 4. Estas possuem uma durabilidade média entre 15 a 25 anos. As EMA's medem de forma autônoma e num intervalo definido, variáveis climáticas como temperatura do ar, umidade relativa do ar, precipitação, radiação solar,velocidade e direção do vento e pressão atmosférica. Os dados são enviados periodicamente para uma central de dados denominada *datalogger* (KNIPPELBERG, 2019).

O INMET, o qual possui EMA's espalhadas por todo o país, coleta esses dados meteorológicos de minuto em minuto, e os envia de hora em hora para sua sede em Brasília, tudo isso é feito via satélite ou por telefonia celular. Os dados passam por um controle rigoroso de qualidade antes de entrarem no banco de dados e ficam disponíveis em tempo real através do site do INMET (INMET, 2011).



Figura 4 – Estação meteorológica automática Araçuaí A566

Fonte: Miranda (2017).

2.3 Redes neurais artificiais

O termo rede neural artificial provém da ideia de que a rede neural artificial funciona de maneira semelhante a rede neural do ser humano. A ideia consiste no fato dessas redes executarem o projeto, semelhante a maneira que a rede neural do cérebro realiza uma determinada tarefa (HAYKIN, 2001).

2.3.1 Evolução das redes neurais artificiais

Durante a Segunda Guerra Mundial, no ano de 1943, Warren McCulloch e Walter Pitts publicaram seu trabalho que modelava um neurônio artificial, baseado no neurônio biológico. Na publicação chamada "*A Logical Calculus of the Ideas Immanent in Nervous Activity*". Neste trabalho, é apresentado uma discussão acerca de redes lógicas de neurônios artificiais e ideias

sobre elementos de decisão de limiar lineares e representações lógicas de várias formas de comportamento e memória (MCCULLOCH; PITTS, 1943).

O foco do trabalho foi descrever um modelo artificial de neurônio juntamente com a apresentação da suas capacidades computacionais e suas técnicas de aprendizagem.

Já o pesquisador Donald Hebb, teve o foco de sua pesquisa nas técnicas de aprendizagem das redes neurais artificiais. No ano de 1949, Hebb publicou *The Organization of Behavior: A Neuropsychological Theory* (A Organização do Comportamento: A Teoria Neuropsicológica). Neste trabalho, o qual originou a teoria de Hebb no meio dos RNAs, foi explicado como ocorre o aprendizado dos neurônios biológicos através do reforço das ligações sinápticas entre os neurônios excitados. (HEBB, 2005).

Além dessa teoria, Widrow e Hoff na publicação *Adaptive Switching Circuits*, elaboraram uma outra técnica de aprendizagem, conhecida como regra de Widrow-Hoff ou regra delta, cuja a técnica se baseia no método do gradiente descendente para reduzir o erro na saída da rede (WIDROW; HOFF, 1960).

Já no ano de 1958, o psicólogo americano Frank Rosenblatt além de demonstrar o seu novo modelo de RNA chamado de *perceptron*, desenvolveu um algoritmo capaz de treinar essa rede para executarem certos tipos de funções (ROSENBLATT, 1958).

Posteriormente, Minsky e Papert, no ano de 1969, publicaram um trabalho chamado *Perceptrons: An Introduction to Computational Geometry* e nele, encontraram uma falha no modelo de Rosenblatt (MINSKY; PAPERT, 1969). De acordo com Braga, Ferreira e Ludermir (2007), este modelo chamado de *perceptron* simples, não conseguia identificar paridade, conectividade e simetria em problemas que não são linearmente separáveis.

O trabalho de Minsky e Papert deram uma amenizada no ânimo das pesquisas na área por alguns anos. Mas no ano de 1982, John Hopfield publicou um artigo chamado Neural Networks and Physical Systems with Emergent Collective Computational Abilities em que, de acordo com Pádua Braga, Leon Ferreira e Ludermir (2007), se mostrava a ligação entre redes recorrentes auto-associativas e sistemas físicos, o que possibilitou o emprego de teorias correntes da física para estudar os modelos (HOPFIELD, 1982).

Além do trabalho de Hopfield (1982) ter contribuído para intensificar os estudos na área de RNAs, um outro fator que impactou positivamente nos estudos e desenvolvimento dos RNAs foi o desenvolvimento da microeletrônica, o que possibilitou a elaboração física dessas redes de neurônios e de suas conexões de uma maneira que antes era impossível.

Com isso, a partir do desenvolvimento do trabalho de Hopfield, até os dias atuais, as pesquisas na área de RNAs passaram por diversas possibilidades. Com o desenvolvimento do algoritmo *backpropagation*, as pesquisas da área focaram em melhorar o algoritmo para que se tivessem um aumento da velocidade de convergência dos resultados. Além disso, passou-se a ter um foco no desenvolvimento do hardware, para aumentar a velocidade de convergência, não ficando limitado somente ao software (BRAGA; FERREIRA; LUDERMIR, 2007).

2.3.2 Funcionamento de uma rede neural artificial

O surgimento das redes neurais artificias, tiveram como base a estrutura e o funcionamento do cérebro humano, como apresentado na subseção 2.3.1.

Dentre as principais características que ressaltam a igualdade entre a rede neural e o cérebro humano, cabe ressaltar a semelhança entre a capacidade de aprendizado com base em iterações com o ambiente externo e também o modo de armazenamento do conhecimento obtido, o qual se da pelas conexões entre os neurônios, chamados de pesos sinápticos.

Assim sendo, para cada parte da estrutura de um RNA, será traçado um paralelo com a respectiva estrutura da rede neural humana.

2.3.2.1 Composição base da rede neural

As redes neurais artificiais são sumariamente compostas de neurônios artificiais os quais estão interligados de modo a receber e transmitir um sinal. Os neurônios os quais recebem informações simultaneamente estão agrupados em camadas (RAUBER, 2005).

Neurônios pertencentes á primeira camada, são denominados neurônios da camada de entrada. O número de neurônios nesta entrada corresponde ao número de variáveis que alimentarão a rede, de acordo com Santos *et al.* (2005).

Na sequência, tendo em vista que cada neurônio da camada de entrada possui conexões com todos os neurônios da camada seguinte, a informação recebida é passada adiante para a rede. Cada neurônio da rede se interliga com cada neurônio da camada seguinte Haykin (2001).

Na última camada da rede neural, a qual é denominada camada de saída, a quantidade de neurônios depende diretamente da quantidade de variáveis de saída presentes no problema proposto. Caso a predição final da rede seja, por exemplo, um único valor numérico, o sistema terá um neurônio na camada de saída.

Para tipos mais complexos de redes neurais, existem além das camadas de entrada e de saída, também existem as camadas intermediárias, também chamadas de ocultas ou escondidas, de acordo com Haykin (2001).

É na passagem dos dados pelas camadas ocultas que ocorre tanto o processamento do problema quanto periodicamente os ajustes dos pesos sinápticos conforme o aprendizado dos neurônios. A definição da quantidade de camadas ocultas pode variar de acordo com a arquitetura utilizada (HAYKIN, 2001).

A Figura 5 ilustra uma rede neural com cinco neurônios na camada de entrada, dois neurônios na camada de saída e duas camadas ocultas. Cada neurônio da camada anterior, se conecta com todos os neurônios da camada seguinte. Além disso, na Figura 5, a primeira camada oculta possui dois neurônios e a segunda camada oculta possui três neurônios. Portanto, a definição da quantidade de neurônios em cada camada oculta varia de acordo com a arquitetura escolhida pelo desenvolvedor (HAYKIN, 2001).



Figura 5 – Topologia de uma rede neural artificial com camada oculta

ENTRADAS

Fonte: Rauber (2005).

Na Figura 6, é possível observar um esquemático do modelo de um neurônio de Mc-Culloch e Pitts (1943) o qual reproduz os elementos centrais do neurônio artificial. São eles, as entradas, os pesos sinápticos, a combinação linear junto á função de ativação e a saída do valor final.





Fonte: Rauber (2005).

O processo de inserção de informações no neurônio se inicia com a injeção dos valores advindos de camadas anteriores ou do ambiente externo, na entrada do elemento. Essas variáveis são representados na Figura 6 por x_1 , x_2 até o x_D (HAYKIN, 2001).

O valor final recebido pelo neurônio em cada entrada depende diretamente do peso sináptico estabelecido em cada uma das conexões. Na Figura 6, essas conexões são representadas pelas variáveis $w_1, w_2, ... \in w_D$, as quais multiplicam respectivamente as entradas $x_1, x_2, ... \in x_D$. Desta forma, os pesos sinápticos implicam o quão relevante é aquela conexão para a resposta final (SILVA; SPATTI; FLAUZINO, 2016).

Além dos pesos sinápticos, é comum que em alguns neurônios de rede, haja uma somatória do resultado previamente obtido pela combinação linear com um valor fixo de modo a aumentar ou diminuir o valor de entrada na função de ativação. Este valor fixo, que também é atualizado durante o treinamento da rede neural, é denominado de *bias* daquele neurônio (FLECK *et al.*, 2016).

O processo de multiplicação das entradas pelos pesos sinápticos, assim como a somatória dos valores ponderados, no neurônio junto ao *bias* é representado pela Equação 1.

$$u = \sum_{i=1}^{D} w_i \cdot x_i + b \tag{1}$$

Sendo que as variáveis x_1 , x_2 até o x_D se referem as entradas, w_1 , w_2 , ... até o w_n se referem aos pesos sinápticos, b é o valor do *bias* e u se refere ao somatório dessa multiplicação.

Após a realização do cálculo através da soma ponderada descrita, o valor obtido passa por uma função de normalização a qual restringe a amplitude de saída do neurônio e permite, através da adição da não-linearidade ao modelo, uma melhor resolução de problemas complexos segundo Zanetti *et al.* (2008).

Esta função detém o nome de função de ativação e sem a mesma, o processamento das variáveis nos neurônios se restringe a uma regressão linear.

Finalmente, tem-se o sinal de saída do neurônio o qual sintetiza o resultado das operações sucessivas explicadas anteriormente e transmite-o, dependendo do mesmo pertencer á camada de saída ou não, para a saída da rede neural ou para os neurônios da camada seguinte.

O conjunto das variáveis de entrada dá origem a uma base de dados, chamada de *dataset*. Esse *dataset* é dividido em três partes distintas, sendo o *dataset* de teste, o *dataset* de treinamento e o *dataset* de validação (LORBACH *et al.*, 2018).

O processo de treinamento se inicia com o *dataset* de treino, o qual vai, de maneira autônoma, alimentar a rede neural com variáveis de entrada e aprender com os erros nas predições comparando o "gabarito" com as variáveis de saída (LORBACH *et al.*, 2018).

Os outros dois *dataset* são usados para mensurar o desempenho da rede e de seus parâmetros internos, sendo que, o *dataset* de validação serve para verificar se o modelo está

convergindo quanto ao aprendizado durante o treinamento e o *dataset* de teste valida o desempenho do modelo após finalizar toda a parte de aprendizado.

Ambos os *dataset* possuem dados diferentes dos apresentados ao modelo pelo *dataset* de treino (LORBACH *et al.*, 2018).

2.3.2.2 Diferentes funções de ativação do neurônio

Conforme descrito na subseção 2.3.2.1, as funções de ativação possuem papel fundamental na saída de cada neurônio. Existe atualmente, diversos tipos de funções cada uma apresentando uma melhor performance dependendo do problema inicial.

Na Figura 6, o resultado da combinação linear é representado pelo somatório da Equação 1, que pela figura, é representado pela saída *net*. Se o valor da saída *net* superar determinado valor μ , a saída binária do neurônio resultará em 1, ou seja, y será igual a 1 (RAUBER, 2005).

Caso o valor *net* não ultrapasse o valor μ , a saída y será igual a 0.

A função que descreve esse comportamento para comparar a saída e resultar em 1 ou 0, é a função Heaviside, também conhecida como função degrau unitário, conforme Figura 7.







O comportamento dessa função é generalizado na Equação 2.

$$u = 0$$
, se $x < c$
 $u = 1$, se $x >= c$ (2)
Sendo $c > 0$

Um outro tipo de função de ativação bastante aplicada nas RNAs é a função linear. O seu comportamento é generalizado na Equação 3.

$$y = a * x + b \tag{3}$$

Para a Figura 8, o valor de *b* da Equação 3, interfere em qual ponto a reta da função linear irá cruzar o eixo Y, sendo que, se *b* for igual a 0, a reta passará pela origem e a variável *a*, irá interferir na inclinação da reta com relação ao eixo X, sendo que, caso *a* seja igual a 1, a retá fará um ângulo 45 graus com o eixo X (RAUBER, 2005).



Figura 8 – Função Linear

Fonte: Rauber (2005).

Uma terceira função utilizada é a função Sigmóide. Essa função é bastante útil quando se deseja que a saída seja um valor real entre 0 e 1. Sendo que sua diferença para a função Heaviside, é de que para valores muito negativos, ela será muito próxima de zero, já para valores muito positivos, ela terá um valor muito próximo de um (RIZZO; CANATO, 2020).

Já para um intervalo de dados para *x* entre -4 e 4, sua saída será um valor entre zero e um, num comportamento que pode ser visto na Figura 9 e descrito pela Equação 4 (RIZZO; CANATO, 2020).



24

$$g(x) = 1/(1 + e^{(-x)})$$
(4)

Além disso, há a função retificada linear, também conhecida como ReLU, utilizada como função de ativação. Seu comportamento é zero para valores menores ou iguais a zero e a partir de zero, seu comportamento é linear, descrito pela Equação 5 e também pode ser observada no Figura 10 (RIZZO; CANATO, 2020; BEZERRA, 2016).

$$f(z) = max(0,z) \tag{5}$$



Figura 10 – Gráfico da representação da Função Retificada Linerar



2.4 Arquiteturas de redes neurais artificiais

A partir do conhecimento dos principais elementos constituintes de uma rede neural artificial, da organização dos neurônios nas camadas e da forma que os mesmos se interligam, tem-se como principais arquiteturas com aplicações contemporâneas:

- Redes *feedforward* (alimentação à frente) de camada simples;
- · Redes feedforward de camadas múltiplas;
- Redes recorrentes ou redes com feedback;
- Redes *mesh*;

De forma a manter coerência com o projeto estudado, serão detalhadas as arquiteturas *feedforward* de camada simples e *feedforward* de camadas múltiplas.

2.4.1 Arquitetura feedforward (alimentação à frente) de camada simples

A *feedforward* de camada simples é composta apenas de duas camadas, a de entrada entrada e a de saída.

Nesse tipo de organização, a qual é ilustrada pela Figura 11, observa-se que a transmissão e o processamento da informação acontece em um sentido unidirecional e que o número de neurônios na camada de saída corresponde exatamente ao número de saídas (respostas ao problema) da rede neural artificial (SILVA; SPATTI; FLAUZINO, 2016).



Figura 11 – Rede feedforward de camada simples

Fonte: Lazzarin et al. (2018).

Com relação a sua aplicação, a arquitetura *feedforward* de camada simples, esta é utilizada para resolver problemas relacionados a classificação de padrões e a filtragem linear, de acordo com Silva, Spatti e Flauzino (2016).

Existem dois possíveis processos de treinamento para o treinamento de RNAs desse porte, são eles, o *Adaline* e o *Perceptron*.

No processo de treinamento *Adaline*, utiliza-se a regra do Delta, o qual o objetivo é minimizar a diferença entre a resposta desejada e a resposta da rede levando em conta todas as amostras de treinamento disponíveis (SILVA; SPATTI; FLAUZINO, 2016).

Entretanto, o processo de treinamento *Perceptron* executa a regra de *Hebb*, a qual dita que ajustes nos pesos sinápticos aconteçam considerando as respostas produzidas por cada amostra de treinamento individualmente (SILVA; SPATTI; FLAUZINO, 2016).

2.4.2 Arquitetura feedforward (alimentação à frente) de múltiplas camadas

A principal diferença estrutural dessa arquitetura para a arquitetura *feedforward* de camada simples é que a de múltiplas camadas possui camadas intermediarias com diferentes quantidades de neurônios. Alguns exemplo de nichos para esta arquitetura são problemas ligados a robótica, classificação de padrões, controle de processos, otimização, identificação de sistemas, etc (SILVA; SPATTI; FLAUZINO, 2016).

O processo de treinamento das redes *feedforward* de camadas múltiplas acontece usando o algorítimo de *backpropagation*, também chamado de regra do delta generalizado. Este algorítimo é composto de dois estágios sucessivos: *forward propagation* e *backward propagation* (SILVA; SPATTI; FLAUZINO, 2016).

A Figura 12 ilustra tanto uma *feedforward* de camadas múltiplas com duas camadas ocultas quanto o direcionamento dos estágios que compõem a regra do delta generalizado.





Fonte: Silva, Spatti e Flauzino (2016).

O estágio de *forward propagation* consiste no fluxo normal discutido anteriormente onde as informações passam pelos neurônios a medida que são ponderados pelos pesos sinápticos e pelas funções de ativação até chegarem na camada de saída.

Ao fim do primeiro estágio, o erro resultante da divergência entre a resposta correta e a resposta da rede neural, é calculado. Para problemas de regressão como o abordado no estudo, este erro é definido pela Raiz do Erro Quadrático Médio (RMSE) mostrado pela Equação 6 (CHAI; DRAXLER, 2014).

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

Onde as variáveis $y \in \hat{y}$ representam respectivamente, os resultados previsto e verdadeiro da rede neural para uma amostra *i* na entrada do sistema e *n* representa o número total de amostras existentes ou, dependendo da função de otimização, o número máximo de amostras processadas antes de uma iteração de atualização dos pesos sinápticos (CHAI; DRAXLER, 2014).

Em seguida, o estágio de *backward propagation*, o qual inicia-se na camada de saída propagando-se até a camada de entrada, calcula-se os gradientes dos pesos sinápticos com base no erro da camada iterada imediatamente antes e atualiza-os utilizando como base, o algoritmo de otimização implementado pelo usuário (SILVA; SPATTI; FLAUZINO, 2016).

Também há a possibilidade de utilizar um outro tipo de erro, chamado de Erro Médio Absoluto (MAE), conforme apresentado na Equação 7 (CHAI; DRAXLER, 2014).

$$\mathsf{MAE}(y, \hat{y}) = \frac{\sum_{i=1}^{N} |y_i - \hat{y}_i|}{N}$$
(7)

Assim como no RMSE, a variáveis y representa o valor previsto e \hat{y} representa o valor verdadeiro para um dado *i* da entrada do sistema e *n* representa a quantidade total de amostras existentes (CHAI; DRAXLER, 2014). Com esses dois valores, a Equação 7 calcula o módulo da diferença entre o previsto e o medido e faz um somatório, para no final, quantificar o desvio nesse treinamento e corrigir o processo.

2.5 Algoritmos de otimização

Redes neurais artificiais podem conter várias camadas e consequentemente, inúmeros pesos entre elas. A retro propagação dos erros cometidos pelas previsões da RNA via técnicas de otimização dos pesos é o que garante o aprendizado do sistema (TAN; LIM, 2019).

O processo de otimização em *machine learning* é comumente aplicado em torno da função objectiva $f(\theta)$ e da definição de um domínio $\theta \in \Theta$. Este processo procura então descrever os valores futuros dos pesos com base no aprendizado adquirido (ANDRYCHOWICZ *et al.*, 2016).

Existem duas categorias de algoritmos de aprendizado utilizados atualmente: algoritmos de primeira ordem e de segunda ordem.

Métodos derivativos de primeira ordem costumam se basear em informações do gradiente para reavaliar os pesos e construir a interação seguinte.

Já os métodos de segunda ordem, utilizam matrizes quadradas como a de Nilsen *et al.* (2019), a qual procura descrever a curvatura local de funções escalares e, com isso, otimizar a trajetória do algoritmo nas iterações (TAN; LIM, 2019).

Alguns dos métodos de otimização mais utilizados nas redes neurais são:

- Gradient descendent method;
- Gradiente descendente estocástico;
- Levenberg-Marquardt method;

De modo a manter a explicação sucinta e direcionada ao problema, será explicado de forma detalhada os algorítimos de otimização *gradient descendent method* e *Levenberg-Marquardt method* com seus respectivos variantes.

2.5.1 Gradient descendent method

A maneira intuitiva de se pensar no método do gradiente descendente, é imaginar um caminho de um rio o qual começa no topo de uma montanha. O objetivo deste otimizador é exatamente o mesmo do rio, realizar o movimento descendente partindo do ponto mais alto rumo aos pontos mais baixos da trajetória (LU, 2022).

O gradiente descendente é visto atualmente como um dos algoritmos de otimização mais populares ao se tratar de redes neurais. Tendo como base a minimização da função objectiva parametrizada pelos pesos da rede neural, este algoritmo busca atualizar os parâmetros do sistema na direção oposta ao gradiente da função (RUDER, 2016).

A fórmula mais genérica da otimização dos pesos no gradiente descendente é mostrada na Equação 8.

$$\theta_n = \theta - \eta \cdot \nabla f(\theta) \tag{8}$$

Onde θ é um dos pesos atuais da rede neural, θ_n é o novo valor do peso ajustado e $\nabla f(\theta)$ é o gradiente da função objetiva.

O *learning rate*, representado na fórmula por η , determina o tamanho do passo que será dado rumo ao mínimo local da função.

Em outras palavras, através do gradiente, segue-se na superfície da curva a direção para baixo rumo a um vale local (ou global) da função. O tamanho do passo dado rumo ao vale é representado pelo *learning rate* o qual pode ser estático ou dinâmico e é definido empiricamente (RUDER, 2016).

A Figura 13 demonstra a trajetória de um dos pesos de uma rede neural. Conforme as interações do gradiente descendente avançam, o erro reduz e converge para um mínimo.

Existem três variantes do algoritmo gradiente descendente que podem ser estudadas a fundo quanto a suas particularidades, estas se diferem primariamente pela quantidade de dados que se usa para calcular o gradiente da função objetiva.



Figura 13 – Otimização de um parâmetro por gradiente descendente genérico

Fonte: Ghosh et al. (2020).

O *trade-off* existente na quantidade de dados usados se dá na relação da precisão do modelo versus o tempo levado para realizar a atualização do peso. São as variantes: *Batch Gradient Descent* (BGD) (gradiente descendente por *Batch, Stochastic Gradient Descent* (SGD) (gradiente descendente estocástico) e *Mini-Batch Gradient Descent* (mBGD) (gradiente descendente por *mini-Batch*) (RUDER, 2016).

2.5.2 Gradiente descendente estocástico

Diferentemente do BGD em que uma interação acontece após o processamento do *dataset* inteiro, o gradiente descendente estocástico realiza uma interação de otimização para cada amostra do *dataset* individualmente.

Como ilustrado na Equação 9, a interação *i* da otimização dos parâmetros da rede neural leva em conta o gradiente resultante da amostra $x^{(i)}$ junto da resposta correspondente $y^{(i)}$.

$$\theta_n = \theta - \eta \cdot \nabla f(\theta; x^{(i)}; y^{(i)}) \tag{9}$$

Devido às interações com amostras semelhantes, o SGD promove redundância à medida que o aprendizado avança.

Como ilustrado na Figura 14, a variância causada por atualizações frequentes na rede neural pelas amostras diversas, tem duas implicações que se contrapõem na atualização dos pesos da rede: a possibilidade de encontro de um mínimo local melhor ou do mínimo global para convergir e uma dificuldade maior de conversão para qualquer um dos mínimos da função (RUDER, 2016).



Figura 14 – Plotagem função de perda versus quantidade de interações no SGD

Entretanto, cabe ressaltar que, ao utilizar o gradiente descendente estocástico juntamente com um *learning rate* interativo que reduz conforme as interações de aprendizado avançam, a conversão dos pesos para um mínimo (local ou global) de forma extremamente lenta e exigem uma quantidade elevada de memória nos seus cálculos de otimização (JENTZEN;

A presença de mínimos locais na função objetiva e a escolha do *learning rate* acabam sendo problemas recorrente nos gradientes descendentes. Tendo em vista que o otimizador não sabe se está convergindo para um mínimo local ou global, corre-se o risco do modelo finalizar o processo de aprendizado em um mínimo local e sem conseguir performar bem nas predições da problemática inicial (HAJI; ABDULAZEEZ, 2021).

2.5.3 Levenberg-Marquardt method

WURSTEMBERGER, 2020).

Sendo nada além de um método heurístico de aprendizado devido ao seu processo bem pensado, o *Levenberg-Marquardt* (LM) se mostra especialmente poderoso no aprendizado em modelos não-lineares de tamanho médio (LU, 2022).

Uma maneira de evitar a convergência problemática do modelo para mínimos locais, é através das informações do gradiente fornecidas por derivadas de segunda ordem sobre a função. O gradiente de segunda-ordem compõe, após algumas generalizações, a chamada matriz de Hessian (RANGANATHAN, 2004).

O algorítimo de otimização de Newton, por exemplo, representa um método de segundaordem eficiente que possibilita a análise sobre a curvatura com base na matriz de Hessian.

Tendo em vista que segundo Ranganathan (2004) o algoritmo de Newton apresenta problemas de taxa de convergência dependendo da linearidade no entorno da localização de início do aprendizado,

O método de *Levenberg-Marquardt* surgiu em 1963 como um algoritmo de segundaordem proveniente da junção do método *Vanilla gradient descendent* e do método de Newton. Desta forma, as vantagens de ambos os métodos se juntam em um só modelo de aprendizado possibilitando ajustes na velocidade de treino baseado no comportamento da *loss function* da rede neural (BILSKI *et al.*, 2020).

Na Equação 10, tem-se a representação do método *Levenberg-Marquardt* já simplificado, onde a matriz de Hessian da função objetiva e sua diagonal são representadas respectivamente por H e diag[H].

$$\theta_n = \theta - (H + \lambda \cdot diag[H])^{-1} \cdot \nabla f(\theta_i)$$
(10)

A variável de ajuste λ da Equação 10 é atualizada na base de 10, conforme o comportamento das interações passadas.

Se como resultado de uma atualização dos pesos, o erro na predição aumentar, significa que existe a necessidade de aumentar a variável de ajuste para elevar a influência do *Vanilla gradient descendent* sobre o processo de conversão. Cabe ressaltar que neste caso, antes de iniciar a interação seguinte, os pesos atualizados de forma errônea voltam ao seu valor antigo.

Contrariamente ao caso acima, conforme o erro na predição diminui, o valor da variável de ajuste decresce e consequentemente, a influência do *Vanilla gradient descendent* sobre o aprendizado também diminui (RANGANATHAN, 2004).

2.6 Redes neurais regressivas médias

Problemas de regressão de complexidade média e alta necessitam arquiteturas robustas, métodos de otimização eficientes, sendo estes normalmente de segunda ordem e testes empíricos com diferentes configurações de camadas e neurônios.

Sendo o problema abordado no projeto de natureza regressiva (previsão de valores numéricos) e possuindo uma quantidade relevante de variáveis de entrada, será utilizado inicialmente uma arquitetura de rede neural *feedforward* de camadas múltiplas com duas camadas ocultas e um único neurônio na camada de saída. As funções de ativação dos neurônios da rede serão Sigmoidal para as camadas ocultas e Linear Retificada para a camada de saída.

O erro das previsões da rede de neurônios sera calculado pelo método do erro quadrático médio e a otimização do pesos sinápticos conforme o erro será feita pelo algoritmo de *Stochastic gradient descent.*

3 METODOLOGIA E DESENVOLVIMENTO

Para poder iniciar o treinamento da rede neural artificial, inicialmente, foi necessário fazer a escolha da base de dados que foi utilizada na rede. Escolhido o banco de dados, é preciso tratar suas inconsistências de modo à, em seguida, extrair características relevantes correlacionadas com a variável a ser prevista.

Essas variáveis relevantes escolhidas foram então modeladas e reorganizadas de forma a possibilitar o treinamento da rede neural. A Figura 15 apresenta as etapas que a base de dados percorreu.



3.1 Aquisição dos dados

O primeiro passo foi escolher a origem dos dados. Como a região de estudo deste trabalho é a cidade de Curitiba, foi utilizada a base de dados gerada a partir da estação meteorológica do INMET localizada na cidade. Dentre os motivos da escolha desta fonte de dados, está o fato da mesma efetuar medições na cidade de Curtiba desde 2003, fornecendo então, uma quantidade expressiva de dados para o treinamento dos modelos.

A estação de Curitiba, a qual é chamada de CURITIBA A807, está localizada na latitude -25.448611 graus, longitude -49.230556 graus, altitude 922.91 metros e sua data de instalação é do dia 27 de janeiro de 2003 (INMET, 2023).

Nas estações meteorológicas automáticas, o INMET faz a captação dos dados e armazena-os em seu banco de dados. As medições acontecem por hora e são disponibilizadas para serem baixadas por ano em formato *csv* no próprio site do INMET.

Apesar das medições mais antigas captadas na cidade de Curitiba serem datadas do ano de 2003, os valores medidos até o ano de 2005 possuem diversas falhas e buracos nos dias. Por essa razão, a base de dados selecionada contém informações obtidas entre os anos de 2006 e 2022.

Para este intervalo de anos descrito, a estação meteorológica A807 captou as medidas instantâneas máximas e mínimas das seguintes variáveis: temperatura ambiente (°C), umidade relativa do ar (%), ponto de orvalho (°C) e pressão atmosférica (hPA). Além disso, também mediu o volume de chuva (mm), a velocidade do vento (m/s), sua direção (°) e as rajadas (m/s).

Por fim, também foi aferida para o período, a medição de irradiação solar em kJ/m^2 , a qual é tema central do trabalho e fundamental para treinamento do modelo.

Inicialmente, esta base inicial completa contava com 6209 dias e, dado que o INMET realiza as medições nas 24 horas do dia, a mesma possuía 149016 registros.

3.2 Processamento dos dados

O passo inicial no tratamento da base escolhida foi a realização de um filtro no período noturno, em que a maior parte das medições são nulas. Esse filtro ocorreu removendo os dados das 22:00 até às 09:00.

Conforme pode-se ver na Figura 16, as irradiações solares medidas nestes horários foram majoritariamente nulas e por isso, se fez necessário um filtro de remoção destes horário em todos os dias da base.

Data	Hora	Tem	peratura	(°C)	U	midade (%	%)	Pto.	Radiação		
	UTC	Inst.	Máx.	Mín.	Inst.	Máx.	Mín.	Inst.	Máx.	Mín.	Kj/m²
11/09/2023	2200	23,5	25,1	23,5	63,0	63,0	57,0	16,1	16,1	15,7	3,20
11/09/2023	2300	22,3	23,5	22,3	68,0	68,0	63,0	16,2	16,2	16,0	
12/09/2023	0000	21,3	22,4	21,3	74,0	74,0	68,0	16,4	16,4	16,1	
12/09/2023	0100	20,2	21,3	20,2	79,0	79,0	74,0	16,3	16,4	16,2	
12/09/2023	0200	19,5	20,2	19,4	82,0	83,0	79,0	16,4	16,5	16,2	
12/09/2023	0300	18,4	19,5	18,4	86,0	86,0	82,0	16,0	16,4	16,0	
12/09/2023	0400	17,6	18,4	17,5	89,0	89,0	86,0	15,7	16,1	15,7	

Figura 16 – Dados medidos pelo INMET na estação Curitiba A807

Fonte: Adaptado de INMET (2023).

Nas medições realizadas pelo INMET, os horários base referenciais, os quais estão na coluna HORA, apresentam-se no fuso-horário Tempo Universal Coordenado (UTC)+0. Tendo em vista que Curitiba está no fuso-horário UTC-3, o filtro dos valores noturnos descrito acima ocorreu na realidade no período das 19:00 até às 06:00 no horário local (IBGE, 2018).

Cabe salientar que, para todas as horas presentes neste trabalho, foi usado o fusohorário UTC+0.

Na sequência, uma limpeza foi feita removendo dados altamente inconsistentes, absurdos ou irrelevantes. Esse processo é conhecido como *data cleaning* (limpeza de dados).

A limpeza de dados é um passo essencial para aumentar as chances da rede neural obter maior acurácia em suas previsões, de acordo com (HAYKIN, 2001).

Não sendo exclusividade da estação meteorológica do INMET de Curitiba, dados captados frequentemente podem apresentar informações impossíveis, como por exemplo, irradiações solares nos valores de -9999 kJ/m^2 , sendo que só existem valores maiores ou iguais a zero para esta variável. As medições podem também, simplesmente, não acontecer por manutenção, defeito ou desligamento do dispositivo de medição.

A Figura 17 mostra um exemplo em que, no dia 12 de março de 2006, a estação não conseguiu aferir nenhuma medições às 16:00, 17:00, 19:00 e 21:00.

Data	Hora	Tem	peratura	(°C)	Ur	nidade (%)	Radiação	Chuva
	UTC	Inst.	Inst. Máx. Mín.		Inst.	Inst. Máx. Mín.		Kj/m²	mm
12/03/2006	1600								
12/03/2006	1700								
12/03/2006	1800	21,4	22,3	21,4	72,0	72,0	63,0	568,00	0,0
12/03/2006	1900								
12/03/2006	2000	21,2	22,3	21,2	71,0	72,0	64,0	172,00	0,0
12/03/2006	2100								
12/03/2006	2200	17,7	19,3	17,7	83,0	83,0	79,0	668,00	0,0
12/03/2006	2300	16,9	17,7	16,9	85,0	85,0	83,0		0,0
13/03/2006	0000	16,5	16,9	16,4	86,0	87,0	85,0		0,0

Figura 17 – Dia com ausência de dados medidos na estação A807

Fonte: Adaptado de INMET (2023).

Constatado o problema descrito acima, foi implementado o expurgo inicial das inconsistências excluindo dias completos onde se detectava mais de um horário com medições inexistentes ou irreais. O dia 12 de março de 2006, o qual foi utilizado como exemplo anteriormente, foi um dos dias excluídos por esta limpeza inicial.

Cabe ressaltar que o motivo da exclusão do dia completo ao invés de apenas os horários com medição avariada se dá pelo fato do modelo necessitar de uma concentração uniforme da quantidade de medições distribuídas nos horários do dia. Caso isso não aconteça, o modelo pode acabar desbalanceado, performando bem em alguns cenários e mal em outros.

O próximo passo foi a eliminação das variáveis pouco relevantes para a determinação da irradiação solar, sendo mantida as seguintes variáveis: precipitação total, pressão atmosférica na estação, irradiação global, temperatura do ar, temperatura máxima, temperatura mínima, direção do vento, rajada máxima de vento e velocidade do vento.

As variáveis temperatura de orvalho e umidade relativa do ar, que seriam inicialmente usadas, foram removidas devido às lacunas existentes nas medições das mesmas. Cabe ressal-

tar que, a única forma de mantê-las no banco de dados seria excluindo completamente os dias onde existiam essas lacunas, tal medida, se realizada, reduziria consideravelmente o tamanho da base de treinamento.

Após finalizar a limpeza e a seleção das variáveis garantindo uma base de treinamento com melhor qualidade, o próximo filtro necessário foi a eliminação dos dias em que existiam duas ou mais horas do dia, com medições de irradiação global com valores impossíveis ou faltantes. Esse filtro se concentrou em eliminar as medições negativas ou iguais a zero.

Assim como, também foi realizado um ajuste nos dias que possuem apenas um horário sem a medição de irradiação global. Essa medida foi tomada sob a premissa de que, tendo em vista que não existem medições para apenas um horário do dia, podemos estimar os valores medidos nesta hora de forma a evitar a remoção do dia completo.

Para a realização deste ajuste, foi criada uma função que analisa se o horário o qual não possui o dado de irradiação se encontra no começo ou nos demais horários do dia. Com base nisso, quando o horário da medida faltante for às 10:00, a função irá pegar a medida das 11:00 e replicar para as 10:00.

Em contra partida, se o horário que estiver faltando a medida de irradiação global for qualquer outro, a função irá pegar o valor da hora anterior e replicar na hora que está faltando o dado.

Por exemplo, nos dias em que faltam somente a irradiação das 12:00, o programa irá pegar a irradiação das 11:00 e replicar para as 12:00.

Cabe destacar que a função descrita acima foi implementada somente para falta de dados na variável de irradiação solar, na ausência de dados em outros outras variáveis, uma função que calcula a média daquela métrica para aquele dia foi aplicada e o resultado obtido foi inserido no valor faltante.

Finalmente, após todas as modificações, limpezas e transformações dos dados, a base se encontrou pronta para ser organizada e possibilitar o treinamento do modelo. Depois de todo o processamento descrito, o conjunto de dados final ficou com 4948 dias com 12 medições horárias das 10:00 até as 21:00, totalizando 59376 registros.

Tendo uma diminuição da base de dados inicial de aproximadamente 60% após os tratamentos, cabe ressaltar que a maior parte desta redução se deu devido a retirada de registros que apresentavam irradiação global nula por se tratarem do período noturno.

Por fim, foi realizado a normalização dos dados através dos valores mínimos e máximos das variáveis. Esse método faz a correção de todos os valores da base de dados para o intervalo entre 0 e 1 sendo 0 e 1 o menor e o maior valor medido para aquela variável respectivamente.

Com isso, a rede recebe somente valores entre zero e um e os valores intermediários são proporcionais ao mínimo e ao máximo. Esse método facilita o processamento da rede, pois padroniza os valores mínimos e máximos de entrada da rede.

3.3 Configuração dos cenários

Com os dados organizados, limpos e tratados conforme os passos da seção 3.2, foi necessário, a partir dos mesmos, modelar a base identificando características correlacionadas com a variável a ser prevista e utiliza-las para treinar o modelo. Cada grupo de características selecionadas corrobora um cenário e é chamado de *dataset* de treinamento.

3.3.1 Modelagem usando *lag* (Atraso)

Para a elaboração do primeiro *dataset*, é preciso entender a lógica do *lag* (atraso), e como ele vai ser usado como uma das características que possibilitou a previsão da irradiação solar em um cenário específico.

O *lag* consiste em pegar um elemento anterior ao momento exato em que se deseja prever determinada variável, este elemento anterior, se pego no momento certo, pode mostrar forte correlação com a variável o qual deseja-se prever.

Utilizando como exemplo o dia 16 de outubro de 2023, às 11:00, apresentado na Figura 18, foi inferido que alguns elementos que parecem estar fortemente correlacionado com a irradiação solar nesta data são a medição de irradiação solar, a temperatura do ar e a precipitação total no dia 16 de setembro de 2023 às 11:00, exatamente um mês antes da data utilizada como base.

Data	Hora	Tem	peratura	(°C)	Radiação	Chuva
	UTC	Inst.	Máx.	Mín.	Kj/m²	mm
16/09/2023	1000	11,4	11,4	11,2	39,10	0,0
16/09/2023	1100	13,2	13,2	11,2	551,00	0,0
16/09/2023	1200	14,7	14,8	12,7	1554,30	0,0

Figura 18 – Dados medidos na estação Curitiba A807

Fonte: Adaptado de INMET (2023).

Este *lag* de um mês atrás aplicado sobre algumas variáveis da base de dados será indicado como $X_{M-i}VARIAVEL$ onde X_{M-} indica um atraso, *i* refere-se à quantidade de meses deste atraso e *VARIAVEL* indica a variável escolhida.

No exemplo descrito, algumas das características usadas para que o modelo preveja a irradiação solar no dia 16 de outubro de 2023 às 11:00, foram os valores de $X_{M-i}_TEMP_AR$, $X_{M-i}_IRRAD_GLOBAL$, $X_{M-i}_PRECIP_TOTAL$, os quais são 551,00; 13,2 e 0,0 respectivamente.

Sumarizando este cenário, conforme a Figura 19, os valores dos *lags* acima foram utilizados na entrada no modelo. A rede neural foi, então, processar seus valores através das funções de ativação dos neurônio e propagar os resultados até a camada de saída, a qual forneceu uma previsão da irradiação solar para a data de referência.





Neste estudo, foram utilizados os *lags* de 1, 2, 12 e 13 meses atrás, os quais são representados pelas notações $X_{M-1}VARIAVEL$, $X_{M-2}VARIAVEL$, $X_{M-12}VARIAVEL$ e $X_{M-13}VARIAVEL$, respectivamente.

Vale ressaltar que, dado que a base escolhida para estudo se inicia no dia 13 de março de 2006, não foi possível extrair os *lags* dos primeiros dias dela. Para contornar isso, nessas datas, foram usados os próprios valores medidos no dia como *lags*.

3.3.2 Modelagem usando médias móveis ponderadas

O segundo método a ser utilizado dentro de alguns cenários é o das médias móveis ponderadas conforme descreve de forma genérica a Equação 11.

$$\mathsf{MM}(X_{MM-i}) = \frac{\sum_{i=1}^{N} (w_i \times v_i)}{\sum_{i=1}^{N} (w_i)}$$
(11)

Sendo o w_i relativo ao peso, e v_i relativo a variável que se está calculando a média móvel. No caso da previsão da irradiação solar, a representação do valor desta variável foi $X_{MM-i}VARIAVEL$, onde X_{MM} representa uma média ponderada e o *-i* refere-se a quantidade de pesos e medidas anteriores que compõem a média.

Diferentemente do método *lag* o qual volta para meses anteriores e coleta dados únicos, o método por média móvel ponderada volta sempre cinco dias anteriores ao dia e hora no qual se deseja realizar a previsão. A partir deste dia e hora anteriores, foram coletadas as últimas *i* medidas existentes da variável para o calculo da média ponderada.

Os pesos da média ponderada são inteiros que vão desde o valor de *i* até 1 sendo aplicados sobre as medidas de forma decrescente, da data e hora mais recente até a mais antiga. As Tabela 1, Tabela 2 e Tabela 3 mostram os pesos para médias móveis com cinco, dez e quinze medidas respectivamente.

Tabela 1	– Média	a móv	vel po	onder	ada c	om 5	medidas
	Peso	P1	P2	P3	P4	P5	
	Valor	5	4	3	2	1	-
	-						-

Fonte: Autoria própria.

Tabela 2 – Média móvel ponderada com 10 medidas

Peso	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10			
Valor	10	9	8	7	6	5	4	3	2	1			
	Fonte: Autoria própria.												

Peso	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15
Valor	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1

Fonte: Autoria própria.

Para exemplificar, deseja-se obter, para a previsão de irradiação solar do dia 15 de outubro de 2023 às 17:00, o valor da média móvel da irradiação solar nesta data. Portanto, como a coleta dos dados da média móvel sempre começa 5 dias antes da data na qual quer prever, foram utilizadas medidas do dia 10 de outubro de 2023.

Neste exemplo em específico, as cinco medidas as quais vão compor o cálculo da X_{MM-5} _*IRRADIACAO_GLOBAL* do dia 15, são os dados de irradiação global das 13:00, 14:00, 15:00, 16:00 e 17:00 horas do dia 10 de outubro de 2023.

Com os dados definidos, o próximo passo foi fazer a média móvel onde, como mostrado na Tabela 1, o valor coletado às 13:00 foi multiplicado pelo peso 1, o das 14:00 pelo peso 2 e assim sucessivamente até o valor das 17:00, que foi multiplicado pelo peso 5. Depois, foi feito o somatório disso e a divisão pela soma de todos os pesos conjuntos.

Foram utilizados para compor os *datasets*, médias móveis com cinco, dez e quinze amostras nas diferentes variáveis da base de dados inicial. As representações destas métricas são representadas por $X_{MM-5}VARIAVEL$, $X_{M-10}VARIAVEL$ e $X_{M-15}VARIAVEL$ respectivamente.

3.3.3 Composição dos testes

Com todos os métodos base das composições dos *datasets* já explicados, serão apresentadas as característica que regem cada um deles. Cada *datasets* servirá como base de aprendizado e validação para uma rede neural.

Esta etapa possibilitou a comparação entre os modelos treinados com *datasets* diferentes e validando qual apresentou as melhores previsões de irradiação solar após o aprendizado.

Como é possível observar na Tabela 4, a qual mostra a composição de cada *datasets*, foram produzidos cinco conjuntos de dados onde cada um possui diferentes composições de variáveis contendo dados anteriores ao momento em que se deseja realizar a previsão.

Número do Dataset	Composição do Dataset
1	X_{M-1} de todo conjunto das variáveis + X_{M-2} da irra-
	diação solar + X_{M-12} da irradiação solar + X_{M-13} da
	irradiação solar
2	X_{M-1} da irradiação solar e temperatura + X_{M-2} da
	irradiação solar
3	X_{M-1} da irradiação solar e temperatura + X_{M-2} da ir-
	radiação solar + X_{MM-5} de todo conjunto das variáveis
	+ X_{MM-10} de todo conjunto das variáveis + X_{MM-15}
	de todo conjunto das variáveis
4	X_{M-1} da irradiação solar + X_{M-2} da irradiação solar +
	X_{M-12} da irradiação solar + X_{M-13} da irradiação solar
	+ X_{MM-5} da irradiação solar + X_{MM-10} da irradiação
	solar + X_{MM-15} da irradiação solar
5	X_{M-1} de todo conjunto das variáveis + X_{M-2} de todo
	conjunto das variáveis + X_{M-12} de todo conjunto das
	variáveis + X_{M-13} de todo conjunto das variáveis +
	X_{MM-5} da irradiação solar + X_{MM-10} da irradiação
	solar + X_{MM-15} da irradiação solar
Enclose Analysis and and	

Tabela 4 –	Composição	dos	datasets
------------	------------	-----	----------

Fonte: Autoria própria.

Como apresentado na seção 3.1, apesar de ser possível deduzir as possíveis variáveis as quais possuem alta correlação com a irradiação solar, a seleção das mesma para os *datasets* é, muitas vezes, feita de forma empírica devido à incapacidade de escolha de variáveis que gerarão resultados melhores frente a complexidade existente dentro de uma rede neural.

Após a definição dos 5 *datasets*, foi feito, como passo final, a separação de cada um deles em *sub-datasets*. Esta medida foi adotada pois Curitiba está numa zona de clima temperado úmido e, segundo o trabalho de TIEPOLO *et al.* (2017), a irradiação solar na cidade varia conforme as estações, sendo a estação com as maiores médias de irradiação, o verão seguido da primavera, do outono e depois, o inverno.

Assim como, através do Atlas de Energia Solar do Estado do Paraná, mostra-se que os meses de maior irradiação solar em Curitiba acontecem no verão, que os meses de menor irradiação solar acontecem no inverno e que as médias de irradiação solar medidas no estado do Paraná para o verão e para o inverno são respectivamente 5,0 a 6,0 kWh/m^2 e 2,7 a 3,5 kWh/m^2 no ano de 2017 (TIEPOLO *et al.*, 2017).

Sumarizando, após todos os procedimentos de montagem e separação dos *datasets* em *sub-datasets*, cada um destes foi utilizado para treinar uma rede neural individualmente. Na totalidade, foram treinados vinte modelos e seus resultados foram comparados entre si.

3.3.4 Parametrização

A determinação das composições dos testes e a separação dos *datasets* em estações, concluiu a parte de organização dos dados. O próximo passo foi utilizar cada um desses *sub- datasets* para treinar uma rede neural individualmente.

Toda parametrização e treinamento foi feito por meio da linguagem de programação Python através das bibliotecas Pandas, Keras, TensorFlow e Scikit-Learn e o ambiente de processamento foi criado através das instâncias dedicadas da ferramenta Google Colab.

A escolha da linguagem de programação Python foi consequência da proximidade com a utilização e por ela possuir todas as ferramentas necessárias para a execução das atividades proposta neste trabalho.

Como discutido no subseção 2.3.2.1, a base a qual seria utilizada para o treinamento do modelo precisava ser dividida de forma aleatória em parte de treino e parte de validação. A proporção de divisão entre dados de treino e dados de validação nos *sub-datasets* foi 80% treino e 20% validação.

Quanto a arquitetura da rede neural, a escolhida foi a *feedforward* com três camadas ocultas. A topologia das redes neurais, a qual se traduz na quantidade e distribuição dos neurônios das camadas ocultas foi variável para cada *datasets* de forma empírica. A camada de saída da rede possuiu sempre um único neurônio representando a previsão da irradiação solar.

As funções de ativação dos neurônios nas camadas ocultas e na camada de saída foram respectivamente Sigmoidal e Linear Retificada. O algoritmo de otimização e aprendizado selecionado foi o *Stocastic gradient descendent*.

Os valores escolhidos para o *batch* de aprendizado, para o *learning rate* e para as épocas de treinamento foram respectivamente 16; 0,1 e 150.

A *loss function* usada foi a função de erro quadrático médio (MSE) e as métricas de acompanhamento de performance dos modelos foram a de raiz do erro quadrático médio (RMSE) e a de erro médio absoluto (MAE). Ambas descritas respectivamente pela Equação 6 e Equação 7.

Vale ressaltar que, para vários parâmetros da rede neural, foram levados em consideração trabalhos anteriores existentes como o de Carvalho, Laboissiere e Fernandes (2021). Como explicado na seção 2.6, as escolhas de parâmetros do modelo são normalmente feitas de forma empíricas, ou seja, se escolhe inicialmente uma opção e de acordo com a evolução da rede, altera-se a sua configuração para tentar melhorar o resultado. O treinamento completo de cada um dos modelos com seu respectivo *sub-datasets* foi realizado quatro vezes e a métrica de erro final obtida foi calculada a partir da média dos erros das quatro interações.

4 RESULTADOS

A configuração apresentada na Capítulo 3 é fruto da elaboração de vários ajustes que foram feitos ao longo do processo de tratamento da base de dados e do treinamento. Inicialmente a análise comportamental dos *datasets* é discutida na seção 4.1 e em seguida os resultados advindos das performances dos modelos são mostrados na seção 4.2.

De forma a trazer tanto os resultados quanto os erros para valores utilizados no cálculo da geração de energia fotovoltaica conforme (TIEPOLO *et al.*, 2017), todos os resultados apresentados nesta sessão foram convertidos de kJ/m^2 , sendo esta a unidade utilizada pela variável de irradiação solar nas medições do INMET, para Wh/m^2 .

4.1 Correlação das variáveis dos datasets

Como parte inicial dos resultados, foram geradas matrizes de correlação para cada um dos *datasets*.

A ideia dessas matrizes de correlação é descrever qual o nível de relação existente entre as variáveis de entrada do conjunto de dados com a variável de saída, que no caso, é a irradiação solar. Na Figura 20 é apresentado essa correlação.

Xm-12_IRRADIACAO_GLOBAL -	0.59	- 1.00
Xm-13_IRRADIACAO_GLOBAL -	0.58	- 0.75
Xm-1_IRRADICAO_GLOBAL -	0.56	
Xm-2_IRRADIACAO_GLOBAL -	0.53	- 0.50
Xm-1_TEMPERATURA_AR -	0.31	
Xm-1_TEMPERATURA_MAX -	0.28	- 0.25
Xm-1_TEMPERATURA_MIN -	0.27	
Xm-1_VELOCIDADE_VENTO -	0.22	- 0.00
Xm-1_RAJADA_MAX_VENTO -	0.21	0.25
Xm-1_DIRECAO_VENTO -	0.097	
Xm-1_TEMPERATURA_ORVALHO -	0.044	0.50
Xm-1_PRECIPITACAO_TOTAL -	-0.02	
Xm-1_PRESSAO_ATMOSFERICA_NA_ESTACAO -	-0.054	0.75
Xm-1_UMIDADE_AR -	-0.28	1.00
	ARADICA CALERA	

Figura 20 – Matriz de correlação dataset 1

Fonte: Autoria Própria.

A matriz de correlação criada na Figura 20, tem seus valores variando entre -1 até 1. Para casos onde o valor é maior que 0 a relação entre as variáveis é diretamente proporcional. Caso a variável apresente um valor negativo, sua relação é inversamente proporcional.

Percebe-se, que na Figura 20, a umidade do ar apresentou uma correlação de -0,28, mostrando quase que completa independência em relação à variável que busca-se prever. Por outro lado, a irradiação solar global para 12, 13, 1 e 2 meses atrás, mostraram as maiores correlações, variando entre 0,59 e 0,53.

Nos casos em que o valor é zero ou próximo de zero, as variáveis em questão são totalmente independentes e não possuem relação entre sí. A matriz que mostra essa correlação para o conjunto de dados 2 é apresentada na Figura 21.



Figura 21 – Matriz de correlação *dataset* 2

Fonte: Autoria Própria.

O *dataset* 2 é apresentando na Figura 21, onde por usar os dados de irradiação global e temperatura do ar, sua correlação ficaram acima de 0,3.

Com base na Figura 22, pode-se ver que as maiores correlações com irradiação solar acontecem em *lags* e médias ponderadas calculadas sobre as variáveis: irradiação solar, temperatura do ar, temperatura máxima e mínima na hora, respectivamente.





Fonte: Autoria Própria.

Além disso, mesmo utilizando nove variáveis diferentes, disponibilizadas pelo INMET, para a geração do *dataset* 3, a irradiação solar segue sendo a variável com maior correlação com a saída da rede, apresentando uma correlação entre 0,44 e 0,54.

Já as demais variáveis, sendo elas, a temperatura do ar, a temperatura máxima, temperatura mínima, velocidade do vento, rajada máxima do vento, pressão atmosférica na estação, direção do vento e precipitação total, sua relação direta, através da média móvel ponderada dos últimos 5 dados, ficaram inferior a correlação da irradiação, resultando de -0,056 a 0,16.

Seguindo analisando a Figura 22, com ênfase na média móvel ponderada de 5, 10 e 15 dados, capta-se que a média móvel com 5 dados, demonstrou, em todas as variáveis, menos na variável de precipitação total, maior correlação do que quando se utiliza 10 ou 15 dados na média móvel.

Também observa-se pela Figura 23, que fazendo um comparativo entre o método *lag* e o método das médias móveis ponderadas, percebe-se que o uso das médias móveis ponderadas apresenta uma menor correlação com a irradiação solar do que o método *lag*. As médias móveis

ficaram com correlação entre 0,44 e 0,2, já pelo método *lag*, a correlação girou entorno de 0,58 e 0,51.



Figura 23 – Matriz de correlação dataset 4

Fonte: Autoria Própria.

Por fim, no último *dataset*, apresentado na Figura 24, é o que há mais variáveis de entrada. Mesmo havendo muitas variáveis de entrada com diferentes atrasos e médias ponderadas, a variável irradiação solar continua sendo a dominante.

No lado oposto, a pressão atmosférica demonstrou ser a variável que sua influência na previsão era inversa, ou seja, para cada aumento de pressão, sua contribuição para a irradiação é a redução da previsão. Essa contribuição inversa ocorreu entre -0,059 a -0,1, no método *lag*.

Além disso, entre -0,1 e 0,098, 12 variáveis demonstraram uma relação próxima de zero. Restringindo para valores entre -0,1 e 0,1, esse número chega a 11 variáveis. Portanto, das 39 variáveis de entrada, aproximadamente 28%, pouco exerceu influência no valor final da irradiação solar previsto pela rede.

Agora, a partir da análise em cada um dos cenários, a variável que possui maior influência, foi a irradiação solar, variando entre 0,54 e 0,59.



Figura 24 – Matriz de correlação dataset 5

Fonte: Autoria Própria.

4.2 Aplicação dos cenários propostos

A aplicação dos cenários propostos se deram por meio do treinamento dos modelos utilizando cada um dos *sub-datasets* criados. A Figura 25 exemplifica, através da redução da *loss function*, o aprendizado ocorrido nas redes neurais das quatro estações do *dataset 5*.

Analisando individualmente os gráficos de aprendizado, observa-se que alguns modelos, a partir de um momento, passaram a decorar os dados de treinamento. Este processo culminou em erros cada vez menores nas previsões sob os dados de treino sem que haja melhora dos erros nas previsões da base de validação.

O processo de superaprendizado da base de treino, o qual é maléfico para a rede neural, faz com que a mesma perca a capacidade de generalização. De forma a evitar o cenário descrito, pode-se, por exemplo, ajustar os parâmetros do modelo de forma empírica. Ajustes dos parâmetros visando a para melhorar os resultados individuais de cada modelo estão fora do escopo inicial deste trabalho.



Figura 25 – Gráfico *loss function* do *dataset* 5 para as estações: (a) Verão, (b) Outono, (c) Inverno e (d) Primavera

Fonte: Autoria Própria.

Alguns exemplos de modelos que decoraram fortemente os dados de treinamento tem sua performance mostrada nas Figura 25 (b) e Figura 25 (d).

Em contra partida, modelos em que a *loss function* de treinamento e validação permaneceram próximas durante todo o processo, demonstram um aprendizado sem perda alguma da capacidade de generalização, o que possibilitou excelentes resultados de previsão sobre a base de validação. Exemplos de aprendizados com essas características estão presentes nas Figura 25 (a) e Figura 25 (c).

Os resultados obtidos decorrente do treinamento de todos os cenários são mostrados em detalhe na Tabela 5. Esta tabela evidencia as métricas de erros coletadas nas previsões de irradiação solar em Curitiba após o treinamento de cada modelo com seu respectivo *sub-dataset* conforme prescrito na Tabela 4.

A topologia indicada na tabela de erros traduz-se na quantidade de neurônios presentes em cada uma das três camadas ocultas da rede neural. Nos treinamentos realizados, foram usados nove neurônios em cada uma dessas camadas. Os termos D1, D2, D3, D4 e D5 referem-

Estação	Métrica	D1	D2	D3	D4	D5
	Topologia	[9 9]	[9 9]	[9 9]	[9 9]	[9 9]
Verão	MAE (Wh/m^2)	171,34	194,56	176,30	166,17	168,55
Verão	RMSE (Wh/m^2)	218,22	236,18	222,40	197,61	214,41
Outono	MAE (Wh/m^2)	133,06	147,82	142,96	133,43	129,85
Outono	RMSE (Wh/m^2)	164,87	177,73	169,70	163,34	162,08
Inverno	MAE (Wh/m^2)	128,94	148,78	135,03	127,41	124,93
Inverno	RMSE (Wh/m^2)	171,25	186,99	180,99	168,65	166,82
Primavera	MAE (Wh/m^2)	192,05	220,34	194,96	205,19	196,37
Primavera	RMSE (Wh/m^2)	233,31	246,71	243,28	231,46	226,47

Tabela 5 – Erro na previsão da irradiação solar em Curitiba

Fonte: Autoria Própria.

se aos *datasets* aplicados nas redes neurais, as variáveis que os compõem estão descritas na Tabela 4.

Os termos de erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE) referem-se as métricas de erro final calculadas entre os resultados obtidos pelas redes neurais (sob o *datasets* de validação) após o processo de aprendizado e os valores reais de irradiação medidos naquele dia e hora.

4.3 Discussão dos resultados obtidos

Conforme é apresentado na Tabela 5, no geral, dois *dataset* tiveram os melhores desempenhos: o D4 e o D5. Além disso, os erros produzidos nas previsões também se alteram de acordo com a métrica sendo analisada, MAE ou RMSE.

No cenário dos resultados acima, apesar das duas métricas de erro descritas representarem a diferença média em Wh/m^2 existente entre os valores de irradiação solar previstos pela rede neural e os valores reais medidos, ambas as fórmulas se diferem em um conceito central: punir exponencialmente ou não, os erros de previsão conforme sua magnitude.

Enquanto a MAE pune de forma igual todas as divergências das previsões, independente do tamanho do erro, o RMSE eleva exponencialmente os erros encontrados. Este comportamento exponencial provoca, para grandes erros, um aumento considerável no valor final. A métrica RMSE foi utilizada no projeto pois, juntamente com a MAE, ela possibilita averiguar quão variado é a amplitude dos erros produzidos pelo modelo. Valores de MAE e de RMSE muito próximos indicam, por exemplo, que o erro médio calculado representa muito bem todas a divergência existente entre as previsões e os valores reais.

A partir dos valores de MAE e RMSE da Tabela 5, pode-se concluir que, devido às diferenças entre estas métricas, as quais variam num intervalo de 20 a 50 Wh/m^2 , nenhum dos modelos possui grande constância nos valores de erros apresentados por suas previsões.

Na Tabela 5, observa-se que a composição D4 apresentou os menores valores de erro no verão com 197,61 Wh/m^2 de RMSE e 166,17 Wh/m^2 de MAE.

Já para o inverno, outono e primavera, o *dataset* D5 performou melhor em ambos os cálculos de erros RMSE e MAE com 166,82 Wh/m^2 e 124,93 Wh/m^2 no inverno, 162,08 Wh/m^2 e 129,85 Wh/m^2 no outono e 226,47 Wh/m^2 e 196,37 Wh/m^2 na primavera.

Vale ressaltar que, através da Tabela 5, identifica-se facilmente que o *dataset* o qual pior performou nas previsões de seus modelos foi o D2 e que a rede neural com os piores resultados foi aquela treinada com o *sub-dataset* da primavera deste conjunto de dados. Os resultados finais obtidos neste cenário foram 246,71 Wh/m^2 de RMSE e 220,34 Wh/m^2 de MAE, os piores da pesquisa.

Finalmente, na Tabela 6, apresenta-se os valores de erro MAE e RMSE do modelo o qual melhor performou nos teste: o de inverno com o *dataset* 5.

	3
	Irradiação Solar
Melhor sub-dataset	D5 - Inverno
MAE	124,93 Wh/m^2
RMSE	166,82 Wh/m^2
Variáveis do	X_{M-1} de todo conjunto das variáveis + X_{M-2} de todo
sub-dataset	conjunto das variáveis + X_{M-12} de todo conjunto das
	Variaveis + Λ_{M-13} de todo conjunto das variaveis +
	X_{MM-5} da irradiação solar + X_{MM-10} da irradiação
	solar + X_{MM-15} da irradiação solar
Topologia	[9 9]

Tabela 6 – Modelo com menor RMSE de Validação

Fonte: Autoria Própria.

A partir dos dados, percebe-se que, mesmo com todo o processo de aprendizado e com a redução de erro apresentado pelos modelos no decorrer do treinamento, as divergências das previsões no melhor modelo permanecem expressivas.

Uma justificativa para essa dificuldade da rede neural, é que tanto a recorrência quanto a alternância da nebulosidade na região de Curitiba são fatores que provoca a variação da irradiação medida na cidade. Segundo o trabalho de TIEPOLO *et al.* (2017), Curitiba está sobre a influência de frentes frias e estas provocam alteração na camada de nuvens da cidade.

Sendo a periodicidade da nebulosidade algo complexo, a rede apresentou dificuldade para compreendê-la. Tendo em vista que as estações do outono e do inverno possuíram os menores valores de erros, observa-se que, nestes períodos do ano, existe uma menor incidência de chuvas e, consequentemente, uma maior constância nos valores de irradiação solar.

Por outro lado, na primavera e no verão, devido a suas características chuvosas presentes principalmente no sul do Brasil, nota-se uma grande influência da nebulosidade nos dias destas estações. Por consequência, uma gama extremamente variável de valores de irradiação solar são medidos nestes períodos mais quentes. As possíveis ações futuras de forma a melhorar dos resultados são discutidas na seção 5.2. Com base nos resultados obtidos anteriormente, os erros RMSE dos modelos foram agrupados por estação e condensados de forma gráfica na Figura 26 de forma a evidenciar a discrepância existente entre os resultados dos mesmos.



Figura 26 – Erros RMSE agrupados por estação

A visualização gráfica agrupada por estação mostra que os maiores erros de previsão aconteceram tanto nos modelos da primavera, com valores acima de 225 Wh/m^2 quanto nos do verão com valores em torno de 220 Wh/m^2 . A partir dessa análise e dos conhecimentos previamente apontados, pode-se concluir que as estações onde existem valores mais elevados de irradiância apresentaram maiores erros de previsão.

Destacando individualmente o modelo da primavera, salienta-se que, através dos tratamentos de dados feitos anteriormente na seção 3.2, é possível assumir que não existe um grande desbalanceamento na quantidade de dados entre as estações. Dito isso, o motivo dos problemas de performance dos modelos da primavera podem advir, por exemplo, de oscilações expressivas nos valores de irradiação solar medidos nos diferentes dias e horários desta estação.

Um fato interessante é que, conforme mostrado nas Figura 26, as estações com as menores irradiações (outono e inverno) apresentaram erros próximos de 175 Wh/m^2 em boa

parte das previsões. Esses erros nestas estações podem acontecer, entre outros motivos, pela constância dos valores de irradiação solar medidos no outono e no inverno. Uma baixa gama de variações nas irradiações solares em diferentes dias faz com que o modelo tenha mais assertividade nas suas previsões

De forma complementar, vale ressaltar que as irradiações solares menores nestas estações se dão pois a cidade de Curitiba está localizada em uma região de clima temperado úmido, conforme Santo (2007) e também, pois a mesma se encontra em uma área de influência de frentes frias. Essas condições provocam a redução da temperatura, chuvas e a formações de nuvens que limitam a irradiação solar.

Além disso, uma outra condição que interfere no regime das chuvas e por consequência, na irradiação solar é o efeito do *El Niño* e da *La Niña* (INPE, 2023).

Finalmente, com base nos resultados apresentados, pode-se ressaltar que o treinamento realizado sobre o modelo utilizando diferentes cenários e uma base de dados robusta ainda não foi o suficiente para obtermos previsões assertivas das irradiações solares em diferentes momentos do ano. Mesmo com os esforços apresentados neste trabalho, ainda existem diversos pontos de melhorias em diferentes aspectos, tanto dos dados de treinamento, quanto da rede neural a ser utilizada.

5 CONCLUSÃO

Desde o ponto inicial de partida para a previsão da irradiação solar na cidade de Curitiba, foram necessárias diversas tomadas de decisão ao longo do percurso para melhor atender as expectativas iniciais. A proposta dos trabalhos realizados neste projeto foi, desde o início, a confecção de uma rede neural treinada que conseguisse estimar os valores de irradiação solar na cidade de Curitiba.

Com essa ideia em mente, o passo inicial foi o estudo de referências bibliográficas sobre o tema e, posteriormente, a escolha do formato da rede neural a ser modelada. Após o aprofundamento no tema, convergiu-se para uma arquitetura inicial com três camadas ocultas e um único neurônio de saída, o qual fez a previsão da irradiação solar. Além disso, foram definidas neste momento, as funções de ativação, a equação do cálculo do erro, o modo de otimização, as métricas de controle, o tamanho e a quantidade das iterações de aprendizado, entre outros detalhes da rede neural.

Após a definição da arquitetura de base, a escolha de um banco de dados que possuísse uma quantidade expressiva de registros e em uma granularidade razoável foi o próximo passo. Para tanto, decidiu-se utilizar o banco de dados meteorológicos do INMET. Com os dados obtidos, foi necessário abordá-los de forma analítica para avaliar quais variáveis de entrada poderiam possibilitar um bom aprendizado sobre os padrões relacionados à irradiação solar.

Definida a estratégia a ser seguida com os dados, foi necessário, primeiramente, fazer uma limpeza dos registros, removendo horários sem dados, com dados de erro e excluindo os horários que não haveriam medição.

Com os dados limpos, foram criados diferentes cenários contendo conjuntos de dados para treinar o modelo. Ao colocar os cenários em teste utilizando o otimizador de segunda ordem *Levenberg-Marquardt*, os resultados apresentados foram insatisfatórios com um desempenho lento e com erros extremamente elevados.

Como alternativa, foi implementado o algoritmo de primeira ordem *Stochastic Gradient Descent*, o qual obteve erros inferiores à primeira tentativa e um treinamento mais rápido.

Todos os tratamentos e análises sobre os dados, assim como a confecção da rede neural, foram feitos através da linguagem Python juntamente com bibliotecas específicas de *Machine Learning*. A utilização desta linguagem possibilitou a automatização completa dos processos, agilizando as etapas e possibilitando análises mais complexas sobre a base.

Tendo em vista que o presente trabalho foi baseado no estudo de Carvalho, Laboissiere e Fernandes (2021), as configurações iniciais da rede neural proposta por eles, para a cidade de São Luís no Maranhão, foram levadas em consideração nas decisões tomadas neste trabalho.

Inicialmente, mesmo aplicando os mesmos cenários para Curitiba, percebeu-se que os erros medidos na previsão de São Luís eram inferiores aos medidos na cidade de Curitiba. Um fator que explica essa diferença é de que a nebulosidade em Curitiba provoca uma variação elevada dos valores de irradiação medida ao longo do ano, dificultando a previsão para dias

específicos com base medições passadas. Já na cidade de São Luís, há uma maior constância nas condições climáticas, sendo mais fácil inferir os seus valores.

Além disso, outro ponto que corrobora a diferença nos resultados é que, durante a elaboração do *dataset* deste trabalho, foram excluídos da base inicial os valores de irradiação solar medidos entre 22:00 às 9:00, diferentemente do trabalho Carvalho, Laboissiere e Fernandes (2021). Manter o intervalo noturno na base de treinamento do modelo faz com que o mesmo consiga acertar boa parte dos resultados. Isso se dá pois a rede neural aprende que para características noturnas, o valor é sempre zero. Acertando boa parte dos valores noturno, o erro do modelo diminui.

Por fim, conforme foi possível observar na Capítulo 4, para cada estação do ano, cada modelo treinado por um *dataset* diferente se mostrou mais vantajoso, atingindo erros menores. Portanto, a ideia de realizar o treinamento da rede neural com diferentes composições de dados demonstrou-se acertiva.

Analisando o modelo que melhor performou, o do *dataset* 5 com dados de inverno, observa-se que este, mesmo obtendo valores de MAE e RMSE inferiores aos outros, apresentou divergências elevadas chegando a 166,82 Wh/m^2 de erro RMSE médio. Este resultado corrobora a ideia de que, mesmo com a implementação de diferentes estratégias visando a elevar a performance, ainda existe um grande espaço para melhoria destes valores em trabalhos futuros.

Como conclusão final, cabe ressaltar que, as aplicações existentes para uma modelo robusto de previsão de irradiação solar são clara uma vez que, esta variável esta diretamente relacionada com a quantidade de energia gerada por painéis fotovoltaicos. Saber com previsibilidade qual será a irradiação solar nos próximos meses em horários específicos permite, por exemplo, uma estimativa fiel da quantidade de energia solar gerada por placas solares instaladas na cidade.

5.1 Dificuldades encontradas no decorrer do estudo

Durante a execução do treinamento da rede, foi constatado que, utilizando o algoritmo inicialmente planejado, o *Levenberg-Marquardt*, a rede neural teve dificuldade no aprendizado dos padrões da irradiação solar. Os erros medidos depois do treinamento da rede foram superiores a expectativa.

A expectativa inicial é que os erros fossem entre 15% e 20%, no entanto, ao fazer as primeiras iterações sobre os *datasets*, foram obtidos erros superiores a 50%. A partir disso, foi alterado o algoritmo para o *Stochastic gradient descent*, resultando em menores erros, conforme apresentado na Tabela 5.

5.2 Possíveis desenvolvimentos futuro

Durante a execução do treinamento, percebeu-se que a utilização da rede neural não precisa ficar limitado à previsão da irradiação solar, como apresentado neste trabalho. Há outras variáveis climáticas que também podem ser treinadas para obter valores futuros. Algumas dessas variáveis são, por exemplo, a temperatura do ar, a chuva acumulada, a umidade relativa do ar, as temperaturas máximas e mínimas, etc.

Como sugestão para trabalhos futuros no desenvolvimento de redes neurais para previsão de irradiação solar, cabe ressaltar que existe uma infinidades de possibilidades, tanto na escolha de novas características para compor os *datasets* quanto estruturalmente em relação a disposição dos componentes do modelo.

Além disso, sobre os dados do INMET, pode-se utilizar também outras bases com outras variáveis meteorológicas medidas. Cabe salientar como possível base de dados, a do Laboratório de Energia Solar (LABENS), a qual, diferentemente da do INMET que mede unicamente a irradiação global, possui medições dos valores de irradiação direta normal e difusa.

No âmbito da rede neural, novos métodos de otimização podem ser adotados e adaptados procurando um melhor aprendizado do modelo e melhores resultados. Paralelo a isso, ainda existe uma gama de parâmetros internos da rede neural que podem ser alterados para viabilizar melhores previsões.

Finalmente, neste trabalho, foram apresentados 5 *datasets*, separados por estação. Todavia, uma outra abordagem possível é priorizar um único *datasets* bem definido e fazer dezenas de combinações das variáveis, com o objetivo de verificar quais agrupamentos possuem maior influência na previsão da irradiação solar.

REFERÊNCIAS

ABNT. **ABNT NBR 10899**: Energia solar fotovoltaica - terminologia. 4. ed. Rio de Janeiro: ABNT, 2006.

ANDRYCHOWICZ, M. *et al.* Learning to learn by gradient descent by gradient descent. **Advances in Neural Information Processing Systems**, v. 29, 2016.

ANOCHI, J. A.; SILVA, J. D. S. Uso de redes neurais artificiais e teoria de conjuntos aproximativos no estudo de padrões climáticos sazonais. **Learning and Nonlinear Models**, v. 7, p. 83–91, 2009.

BAPTISTA, J. P. M. **Distribuição angular da radiação solar: aplicação do modelo de Perez**. 2016. Dissertação (Mestrado) — Universidade de Lisboa, 2016.

BEZERRA, E. Introdução à aprendizagem profunda. Artigo -31º Simpósio Brasileiro de Banco de Dados, Salvador, 2016.

BILSKI, J. *et al.* Local Levenberg-Marquardt algorithm for learning feedforwad neural networks. **Journal of Artificial Intelligence and Soft Computing Research**, v. 10, n. 4, p. 299–316, 2020.

BRAGA, A. P.; FERREIRA, A. C. P. de L.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria** e Aplicações. [*S.l.*]: LTC editora, 2007.

CARVALHO, W. K. M.; LABOISSIERE, L. A.; FERNANDES, R. A. S. Previsão de irradiação solar e temperatura do ar utilizando redes neurais artificiais para a cidade de São Luís-MA. **Pluris 2021 Digital**, 2021.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)?– arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, Copernicus Publications Göttingen, Germany, v. 7, n. 3, p. 1247–1250, 2014.

EPE. Plano decenal de expansão de energia 2031. **Ministério de Minas e Energia**, p. 69–73, 2022.

FLECK, L. *et al.* Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016.

GHARAT, S. **O quê, por que e qual ?? Funções de Ativação.** 2019. Disponível em: https://medium.com/@snaily16/what-why-and-which-activation-functions-b2bf748c0441. Acesso em: 11 nov. 2023.

GHOSH *et al.* An empirical analysis of generative adversarial network training times with varying batch sizes. *In*: **The 11**^{*th*} **IEEE Annual Ubiquitous Computing, Electronics and Mobile Communcation Conference**. [*S.I.*: *s.n.*], 2020.

HAJI, S. H.; ABDULAZEEZ, A. M. Comparison of optimization techniques based on gradient descent algorithm: a review. **PalArch's Journal of Archaeology of Egypt/Egyptology**, v. 18, n. 4, p. 2715–2743, 2021.

HAYKIN, S. **Redes Neurais Artificiais: Princípios e Práticas**. 2. ed. Porto Alegre: Editora Bookman, 2001.

HEBB, D. O. **The Organization of Behavior: A Neuropsychological Theory**. [*S.l.*]: Psychology Press, 2005.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences**, National Academy Sciences, v. 79, n. 8, p. 2554–2558, 1982.

IBGE. Fuso horário civil - 2018. **Ministério do Planejamento e Orçamento**, 2018. Disponível em: https://atlasescolar.ibge.gov.br/images/atlas/mapas_brasil/brasil_fuso_horario.pdf. Acesso em: 30 nov. 2023.

INMET. Nota técnica nº. 001/2011/SEGER/LAIME/CSC/INMET: Rede de estações meteorológicas automáticas do INMET. Brasília, 2011.

INMET. Dados meteorológicos: Estações automáticas. **Ministério da Agricultura e Pecuária**, 2023. Disponível em: https://tempo.inmet.gov.br/TabelaEstacoes/A807. Acesso em: 21 sep. 2023.

INPE. Condições atuais do enos: caracterização do El-Niño. **Centro de Previsão de Tempo e Estudos Climáticos (CPTEC)**, 2023. Disponível em: http://enos.cptec.inpe.br/. Acesso em: 12 nov. 2023.

JENTZEN, A.; WURSTEMBERGER, P. von. Lower error bounds for the stochastic gradient descent optimization algorithm: sharp convergence rates for slowly and fast decaying learning rates. **Journal of Complexity**, Elsevier, v. 57, 2020.

KNIPPELBERG, F. M. Estações meteorológicas: funcionamento e a sua importância na agricultura. **PROCEV: Pro Reitoria de Cultura Extensão e Vivência**, 2019. Disponível em: https://evento.ufmt.br/download/sub_fd6e78251792ea16591cd8ca2c063ba1.pdf. Acesso em: 12 out. 2022.

LAZZARIN, L. N. *et al.* Redes neurais feedforward aplicadas na avaliação do impacto da poluição atmosférica e variáveis climáticas na saúde humana. *In*: **Proceedings of the 1**st **Iberic Conference on Theoretical and Experimental Mechanics and Materials**. [*S.I.*: *s.n.*], 2018. v. 11, p. 275–284.

LORBACH, M. *et al. Learning to recognize rat social behavior: novel dataset and cross-dataset application.* **Journal of Neuroscience Methods**, v. 300, p. 166–172, 2018. Disponível em: https://www.sciencedirect.com/science/article/pii/S0165027017301255. Acesso em: 28 nov. 2022.

LU, J. Gradient descent, stochastic optimization, and other tales. **arXiv preprint arXiv:2205.00832**, 2022.

MARQUES, L. O antropoceno como aceleração do aquecimento global. **Liinc em Revista**, v. 18, n. 1, p. e5968, 2022. Disponível em: https://revista.ibict.br/liinc/article/view/5968. Acesso em: 11 out. 2022.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Springer, v. 5, p. 115–133, 1943.

MINSKY, M.; PAPERT, S. **Perceptrons: an Introduction to Computational Geometry**. [*S.l.*]: MIT Press, 1969.

MIRANDA, A. **INMET Conclui Instalação de Estação Meteorológica Automática no Campus Araçuaí**. 2017. Site do Instituto Federal do Norte de Minas Gerais. Disponível em: https://www.ifnmg.edu.br/noticias-ara/noticias-2017/ 15583-inmet-conclui-instalacao-de-estacao-meteorologica-automatica-no-campus-aracuai. Acesso em: 11 nov. 2023.

NILSEN, G. K. *et al.* Efficient computation of hessian matrices in tensorflow. **arXiv preprint arXiv:1905.05559**, 2019.

PEREIRA, E. B. *et al.* **Atlas brasileiro de energia solar**. 2. ed. São José dos Campos: INPE, 2017. 80 p. Disponível em: http://doi.org/10.34024/978851700089. Acesso em: 10 out. 2022.

PINHO, J. T.; GALDINO, M. A. **Manual de Engenharia para Sistemas Fotovoltaicos**. Rio de Janeiro: CEPEL - CRESESB, 2014. Disponível em: http://www.cresesb.cepel.br/publicacoes/ download/Manual_de_Engenharia_FV_2014.pdf. Acesso em: 12 out. 2022.

RANGANATHAN, A. The Levenberg-Marquardt algorithm. **Tutoral on LM algorithm**, v. 11, n. 1, p. 101–110, 2004.

RAUBER, T. W. Redes neurais artificiais. Universidade Federal do Espírito Santo, 2005.

RIZZO, I. V.; CANATO, R. L. C. Inteligência artificial: funções de ativação. **Prospectus (ISSN: 2674-8576)**, v. 2, n. 2, 2020.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

RUDER, S. An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**, 2016.

SANTO, C. d. J. E. **Classificação Climática do Estado do Paraná.** 2007. Disponível em: http://www.geografia.seed.pr.gov.br/modules/galeria/detalhe.php?foto=1570&evento=8. Acesso em: 12 nov. 2023.

SANTOS, A. M. *et al.* Usando redes neurais artificiais e regressão logística na predição da hepatite A. **Revista Brasileira de Epidemiologia**, SciELO Public Health, v. 8, n. 2, p. 117–126, 2005.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. 2. ed. [*S.I.*]: Artliber, 2016.

SILVA, R. A. e *et al.* Estudo da variabilidade da radiação solar no nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 14, p. 501–509, 2010.

TAN, H. H.; LIM, K. H. Review of second-order optimization techniques in artificial neural networks backpropagation. *In*: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [*S.I.*], 2019. v. 495, n. 1.

TIEPOLO, G. M. *et al.* Atlas de Energia Solar do Estado do Paraná. Curitiba-PR: UTFPR, 2017. v. 2.

WIDROW, B.; HOFF, M. E. Adaptive Switching Circuits. [S.I.], 1960.

ZANETTI, S. S. *et al.* Estimação da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, SciELO Brasil, v. 12, p. 174–180, 2008.