

# UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-BRASILEIRA INSTITUTO DE ENGENHARIA E DESENVOLVIMENTO SUSTENTÁVEL CURSO DE GRADUAÇÃO EM ENGENHARIA DA COMPUTAÇÃO

MANUEL FINDA EVARISTO

PREVISÃO DE MÉDIO PRAZO DA IRRADIAÇÃO SOLAR, UTILIZANDO REDES NEURAIS ARTIFICIAIS RECORRENTES LSTM, ATRAVÉS DE DADOS HISTÓRICOS COLETADOS DE UMA ESTAÇÃO METEOROLÓGICA NO MUNICÍPIO DE REDENÇÃO-CE NO PERÍODO DE 2020 E 2022

REDENÇÃO

2024

## MANUEL FINDA EVARISTO

# PREVISÃO DE MÉDIO PRAZO DA IRRADIAÇÃO SOLAR, UTILIZANDO REDES NEURAIS ARTIFICIAIS RECORRENTES LSTM, ATRAVÉS DE DADOS HISTÓRICOS COLETADOS DE UMA ESTAÇÃO METEOROLÓGICA NO MUNICÍPIO DE REDENÇÃO-CE NO PERÍODO DE 2020 E 2022

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia da Computação do Instituto de Engenharia e Desenvolvimento Sustentável da Universidade da integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial à obtenção do grau de bacharel em Engenharia da Computação.

Orientadora: Prof. Dra. Lígia Maria Carvalho Sousa

Coorientador: Prof. Dr. Luís Otávio Rigo Júnior

#### Universidade da Integração Internacional da Lusofonia Afro-Brasileira Sistema de Bibliotecas da UNILAB Catalogação de Publicação na Fonte.

Evaristo, Manuel Finda.

E92p

Previsão de médio prazo da irradiação solar, utilizando redes neurais artificiais recorrentes ISTM, através de dados históricos coletados de uma estação meteorológica no município de Redenção-CE no período de 2020 e 2022 / Manuel Finda Evaristo. - Redenção, 2024. 63f: il.

Monografia - Curso de Engenharia De Computação, Instituto De Engenharias E Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2024.

Orientador: Prof. Dra. Lígia Maria Carvalho Sousa. Coorientador: Prof. Dr. Luís Otávio Rigo Júnior.

1. Irradiação solar (Energia solar). 2. Previsão. 3. Long Short-Term Memory (LSTM). 4. Energia solar fotovoltaicos. 5. Clima tropical. I. Título

### MANUEL FINDA EVARISTO

# PREVISÃO DE MÉDIO PRAZO DA IRRADIAÇÃO SOLAR, UTILIZANDO REDES NEURAIS ARTIFICIAIS RECORRENTES LSTM, ATRAVÉS DE DADOS HISTÓRICOS COLETADOS DE UMA ESTAÇÃO METEOROLÓGICA NO MUNICÍPIO DE REDENÇÃO-CE NO PERÍODO DE 2020 E 2022

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia da Computação do Instituto de Engenharia e Desenvolvimento Sustentável da Universidade da integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial à obtenção do grau de bacharel em Engenharia da Computação.

Aprovada em: 04 de Setembro de 2024

### BANCA EXAMINADORA

Prof. Dra. Lígia Maria Carvalho Sousa (Orientadora) Universidade da integração Internacional da Lusofonia Afro-Brasileira(UNILAB)

Prof. Dr. Luís Otávio Rigo Júnior (Coorientador) Universidade da Integração Internacional da Lusofonia Afro-Brasileira(UNILAB)

Prof. Dr. Vandilberto Pereira Pinto Universidade da Integração Internacional da Lusofonia Afro-Brasileira(UNILAB)

#### AGRADECIMENTOS

À Prof.<sup>a</sup> Dr.<sup>a</sup> Lígia Maria Carvalho Sousa, por me orientar neste TCC e pela oportunidade e todo conhecimento compartilhado no Grupo de Processamento e Gerenciamento de Energias Renováveis e Controle (PGERC).

Ao Prof. Dr. Luís Otávio Rigo Júnior, pela coorientação deste projeto. Graças à sua grande contribuição, foi possível o desenvolvimento prático do trabalho.

Ao Prof. Dr. Sabi Yari Moïse Bandiri, que durante os cinco anos da minha graduação esteve sempre ao meu lado, dando todo o suporte necessário, tanto do ponto de vista pessoal quanto acadêmico. O senhor foi um amigo e um irmão mais velho.

Ao aluno Manuel Lucala Zendo, meu amigo, irmão e colega do curso de Engenharia da Computação da UNILAB, com quem, durante todo o período de formação, nos incentivamos mutuamente a fim de alcançarmos bom desempenho e concluirmos o curso com êxito.

Ao Prof. Dr. Tales Paiva Nogueira, do IEDS, pelos ensinamentos e pelos ótimos conselhos concedidos durante minha trajetória na UNILAB.

Ao meu primo e aluno de Sociologia da UNILAB, Manuel Mfinda Pedro Marques, pelo companheirismo. Como minha única família de sangue aqui no Brasil, nos unimos e, graças a Deus, tudo deu certo. Muito obrigado, irmão!

Ao meu Tio, Simão Manuel Finda, expresso minha profunda gratidão pelos ensinamentos, pelo suporte financeiro, emocional e motivacional que me proporcionou. O senhor é muito mais que um tio para mim, é como um pai. Nenhuma palavra escrita seria capaz de descrever com exatidão o quão importante e significativo o senhor é em minha vida. Sua presença constante, seus conselhos valiosos e seu apoio incondicional foram fundamentais para que eu chegasse até aqui. Sou eternamente grato por tudo o que o senhor fez e continua fazendo por mim. Seu exemplo de determinação, retidão e generosidade será sempre uma inspiração para mim.

À toda minha família, especialmente aos meus pais, irmãos e sobrinhos, que compreenderam minha ausência devido à dedicação aos estudos superiores!

Estendo meus sinceros agradecimentos ao corpo docente, que não apenas transmitiu conhecimentos teóricos, mas também nutriu o desenvolvimento do meu caráter e da sensibilidade necessários ao processo educacional e à formação profissional.

E à Fundação Cearense de Apoio ao Desenvolvimento (FUNCAP), pelo financiamento da pesquisa no projeto do PGERC.

#### **RESUMO**

A energia solar fotovoltaica é uma fonte de energia limpa e renovável que utiliza a radiação solar para produzir eletricidade. Seu desenvolvimento vem crescendo muito rapidamente nos últimos anos devido ao aprimoramento tecnológico e ao apoio governamental a esta fonte de produção de energia elétrica. Um dos aspectos que afeta diretamente a eficiência da geração fotovoltaica é o fator climático, portanto estudar o impacto das variáveis climatológicas, como a irradiância solar, e propor ações que mitiguem tais impactos pode proporcionar ainda mais o crescimento desta fonte de geração de energia. Este estudo apresenta o desenvolvimento e avaliação de modelos de redes neurais recorrentes LSTM (do inglês, *Long Short-Term Memory*) para a previsão de irradiação solar de médio prazo na região de Redenção-CE. Utilizando dados históricos de irradiação solar coletados por uma estação meteorológica local, foram treinados três modelos LSTM com diferentes arquiteturas e hiperparâmetros. Os resultados demonstraram a capacidade dos modelos em capturar padrões temporais complexos e produzir previsões precisas, com destaque para o Modelo 003, que obteve os menores valores de perda, MAE (do inglês, Mean Absolut Error) e MSE (do inglês, Mean Square Error). A análise dos gráficos de previsão revelou a habilidade dos modelos em reproduzir a sazonalidade diária e os padrões presentes nos dados reais. Esses resultados promissores abrem caminho para a aplicação de modelos LSTM na otimização de sistemas fotovoltaicos na região. No entanto, limitações como a consideração de apenas uma variável de entrada e a avaliação em uma única estação meteorológica foram identificadas. Trabalhos futuros podem explorar a inclusão de variáveis meteorológicas adicionais, arquiteturas mais complexas e a integração com sistemas de controle e otimização de energia solar.

Palavras-chave: Irradiação solar. Previsão. LSTM. Fotovoltaicos. Clima Tropical.

#### ABSTRACT

Photovoltaic solar energy is a clean and renewable source of energy that uses solar radiation to produce electricity. Its development has been growing very fast in recent years due to technological improvement and government support for this electricity production source. One of the aspects that directly affects the efficiency of photovoltaic generation is the climatic factor, so studying the impact of climatological variables, such as solar irradiance, and proposing ways to mitigate such impacts is an important way to further provide for the growth of this source of energy generation. This study presents the development and evaluation of Long Short-Term Memory (LSTM) recurrent neural network models for medium-term solar irradiation prediction in the Redenção-CE region. Using historical solar irradiation data collected by a local weather station, three LSTM models with different architectures and hyperparameters were trained. The results demonstrated the models' ability to capture complex temporal patterns and produce accurate predictions, with Model 003 standing out for achieving the lowest loss, MAE (Mean Absolut Error), and MSE (Mean Square Error) values. Analysis of the prediction plots revealed the models' capability to reproduce daily seasonality and patterns present in the real data. These promising results pave the way for the application of LSTM models in optimizing photovoltaic systems in the region. However, limitations such as considering only one input variable and evaluation at a single weather station were identified. Future work may explore the inclusion of additional meteorological variables, more complex architectures, and integration with energy control and optimization systems.

Keywords: Solar Irradiation. Prediction. LSTM. Photovoltaic. Tropical Weather.

# LISTA DE FIGURAS

Figura 1 – Evolução da Fonte Solar Fotovoltaica no Brasil	15
Figura 2 – Tipos de irradiação solar	16
Figura 3 – Variação da irradiação solar média anual no Brasil	18
Figura 4 – Representação de um neurônio artificial	21
Figura 5 – Estrutura de uma rede neural feedforward com duas camada oculta	23
Figura 6 – Arquitetura Básica da Célula RNN	24
Figura 7 – Arquitetura Básica de uma Célula LSTM	25
Figura 8 – Arquitetura Básica de uma Célula GRU	27
Figura 9 – Fluxograma da metodologia adotada	41
Figura 10 – Setup da estação meteorológica e processo de coleta de dados	42
Figura 11 – Fluxograma do Pré-processamento dos Dados	43
Figura 12 – Divisão dos dados	44
Figura 13 – Desempenho do Modelo 001 na previsão de irradiação solar	49
Figura 14 – Desempenho do Modelo 002 na previsão de irradiação solar.	49
Figura 15 – Desempenho do Modelo 003 na previsão de irradiação solar.	50

# LISTA DE TABELAS

Image: Tabela 1 – Hiperparâmetros e tamanho da janela dos modelos LSTM.         Image: Tabela 1 – Hiperparâmetros e tamanho da janela dos modelos LSTM.	48
Tabela 2 – Desempenho dos modelos LSTM no conjunto de treinamento.	48
Tabela 3 – Desempenho dos modelos LSTM no conjunto de teste.	48

### LISTA DE ABREVIATURAS E SIGLAS

- ARIMA Autoregressive Integrated Moving Average
- GRU Gated Recurrent Unit
- LSTM Long Short-Term Memory
- MLP Multilayer Perceptron
- PNT Previsão Numérica do Tempo
- ReLU unidade linear retificada
- RNAs Redes Neurais Artificiais
- RNNs Recurrent Neural Networks
- tanh tangente hiperbólica

# SUMÁRIO

1	INTRODUÇÃO	12
2	REFERENCIAL TEÓRICA	14
2.1	Energia Solar e Irradiação Solar	14
2.1.1	Introdução à energia solar	14
2.1.2	Conceitos fundamentais de irradiação solar	15
2.1.3	Tipos de Irradiação Solar	16
2.1.4	Fatores que influenciam a irradiação solar	17
2.1.5	Importância da previsão da irradiação solar para sistemas de energia solar	19
2.1.6	Métodos tradicionais de previsão da irradiação solar	19
2.2	Redes Neurais Artificiais e Aprendizado de Máquina	20
2.2.1	Introdução às Redes Neurais Artificiais	20
2.2.2	Arquiteturas de RNAs	22
2.2.2.1	Redes neurais feedforward	22
2.2.2.2	Redes neurais recorrentes (RNNs)	24
2.2.2.2.1	Redes Long Short-Term Memory (LSTM)	25
2.2.2.2.2	Redes Gated Recurrent Unit (GRU)	26
2.2.2.2.3	Comparação entre RNN, LSTM e GRU	27
2.2.3	Treinamento de RNAs	28
2.2.3.1	Aprendizado supervisionado	28
2.2.3.1.1	Inicialização dos pesos	29
2.2.3.1.2	Normalização dos dados de entrada	30
2.2.3.1.3	Escolha da função de ativação	32
2.2.3.1.4	Escolha da função de erro	33
2.2.3.1.5	Definição dos hiperparâmetros	33
2.2.3.2	Técnicas de regularização	35
2.2.3.3	Algoritmos de treinamento	36
2.2.3.4	Métricas de avaliação de desempenho de modelos de previsão	38
2.3	Aplicação de Redes Neurais Recorrentes na Previsão de Irradiação Solar	39
2.3.1	Estado da Arte na Previsão de Irradiação Solar com RNNs	39
3	METODOLOGIA	41

3.1	<b>Coleta de Dados</b>
3.2	Pré-processamento de Dados 43
3.3	Análise das Lacunas de Dados
3.4	Implementação do Modelo LSTM       45
3.5	Métricas de Avaliação do Modelo
4	<b>RESULTADOS</b> 48
5	<b>CONCLUSÕES E TRABALHOS FUTUROS</b> 52
	<b>REFERÊNCIAS</b> 54

### 1 INTRODUÇÃO

A energia solar é uma fonte renovável e sustentável de energia que tem ganhado cada vez mais destaque nos últimos anos. A irradiação solar, que é a quantidade de energia solar que atinge a superfície da Terra, é um fator preponderante para o aproveitamento dessa fonte de energia (PEREIRA *et al.*, 2017). A previsão da irradiação solar é fundamental para o planejamento e operação de sistemas de energia solar, como painéis fotovoltaicos e sistemas de aquecimento solar (INMAN *et al.*, 2013).

As Redes Neurais Artificiais (RNAs) têm se mostrado uma ferramenta promissora para a previsão de séries temporais, incluindo a irradiação solar (VOYANT *et al.*, 2017). As RNAs são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de aprender padrões complexos a partir de dados históricos (HAYKIN, 2009). As Redes Neurais Recorrentes ou Recurrent Neural Networks (RNNs), em particular, são especialmente adequadas para lidar com dados sequenciais, como séries temporais, devido à sua capacidade de memória interna (GOODFELLOW *et al.*, 2016).

Neste contexto, o presente trabalho tem como desenvolver e avaliar um modelo de previsão de irradiação solar de médio prazo usando redes neurais LSTM, com o intuito de otimizar a operação e o planejamento de sistemas fotovoltaicos na região de Redenção-CE. Para alcançar esse objetivo, os seguintes objetivos específicos foram definidos: (i) coletar e pré-processar dados históricos de irradiação solar da estação de Redenção-CE (dezembro de 2020 - setembro de 2022); (ii) implementar e treinar diferentes arquiteturas de redes neurais LSTM para previsão de irradiação solar de médio prazo usando apenas dados de irradiação como entrada; (iii) avaliar o desempenho dos modelos LSTM usando métricas de erro e comparar as arquiteturas para identificar a mais eficaz para a previsão de irradiação baseada apenas em dados de irradiação; e (iv) analisar a capacidade do modelo LSTM em capturar padrões temporais na irradiação solar e discutir a aplicação potencial do modelo para otimizar sistemas fotovoltaicos em Redenção-CE, considerando as limitações da abordagem de única variável.

A hipótese levantada neste trabalho é que as RNNs podem ser utilizadas para prever com precisão a irradiação solar de médio prazo, utilizando dados históricos coletados de uma estação meteorológica no município de Redenção-CE no período de 2020 e 2022.

A metodologia adotada será dividida em etapas, visando alcançar os objetivos propostos de forma estruturada e sistemática. Quanto à finalidade, trata-se de uma pesquisa aplicada, pois busca gerar conhecimentos para aplicação prática dirigidos à solução de problemas específicos (PRODANOV; FREITAS, 2013). Em relação aos objetivos, a pesquisa é descritiva e exploratória, uma vez que visa descrever as características de um fenômeno e proporcionar maior familiaridade com o problema (GIL, 2002).

A abordagem utilizada será tanto quantitativa quanto qualitativa. A abordagem quantitativa será empregada na coleta, processamento e análise dos dados históricos de irradiação solar, bem como no treinamento, teste dos modelos de RNNs. Já a abordagem qualitativa será aplicada na interpretação dos resultados e na discussão dos impactos e implicações da previsão da irradiação solar (CRESWELL, 2010).

O método de pesquisa adotado é o hipotético-dedutivo, no qual se parte de uma hipótese, que é testada por meio de experimentos e observações, para se chegar a uma conclusão (MARCONI; LAKATOS, 2003). Quanto aos procedimentos, será realizada uma pesquisa experimental, na qual se determina um objeto de estudo, selecionam-se as variáveis capazes de influenciá-lo e definem-se as formas de controle e observação dos efeitos que a variável produz no objeto (GIL, 2002).

A relevância deste trabalho reside na contribuição para o avanço do conhecimento científico na área de previsão da irradiação solar utilizando técnicas de inteligência artificial, bem como no potencial de aplicação prática dos resultados obtidos para o planejamento e gestão de sistemas de energia solar na região estudada. Além disso, espera-se que este estudo possa servir de base para futuras pesquisas na área de previsão de séries temporais aplicada à irradiação sola, ampliando o escopo e a abrangência da aplicação das RNNs para a previsão da irradiação solar em diferentes contextos e localidades.

A estrutura do trabalho está organizada da seguinte forma: no Capítulo 2, são apresentados os conceitos fundamentais sobre irradiação solar e redes neurais recorrentes, bem como uma revisão da literatura sobre a aplicação dessas técnicas para a previsão da irradiação solar. No Capítulo 3, são descritos os procedimentos metodológicos adotados, incluindo a coleta e pré-processamento dos dados, a arquitetura e o treinamento dos modelos de RNNs. No Capítulo 4, são apresentados e discutidos os resultados obtidos. Por fim, no Capítulo 5, são apresentadas as conclusões do trabalho, as limitações encontradas e as perspectivas para trabalhos futuros. Com isso, busca-se fornecer uma visão abrangente e aprofundada sobre o potencial das RNNs para a previsão da irradiação solar, contribuindo para o avanço da pesquisa e da aplicação prática nessa área.

#### 2 REFERENCIAL TEÓRICA

Este capítulo está organizado em três seções principais, que visam fundamentar e contextualizar a pesquisa sobre a previsão da irradiação solar utilizando redes neurais artificiais recorrentes.

A seção 2.1, "Energia Solar e Irradiação Solar", apresentará uma visão geral sobre a energia solar, discutindo conceitos fundamentais, fatores influentes e a importância da previsão da irradiação solar para sistemas de energia solar.

A seção 2.2, "Redes Neurais Artificiais e Aprendizado de Máquina", introduzirá os conceitos básicos das RNAs e do aprendizado de máquina, explorando arquiteturas, treinamento e aplicações na previsão de séries temporais.

A seção 2.3.1, "Aplicação de Redes Neurais Recorrentes na Previsão de Irradiação Solar", aprofundará a discussão sobre o uso específico das RNNs para a previsão da irradiação solar, abordando o estado da arte, tipos de RNNs, pré-processamento de dados, estratégias de treinamento e validação, interpretação dos resultados e desafios.

Espera-se que este referencial teórico forneça uma base sólida para a compreensão do tema e das metodologias empregadas, contribuindo para o avanço do conhecimento na área de previsão da irradiação solar utilizando redes neurais artificiais recorrentes.

#### 2.1 Energia Solar e Irradiação Solar

#### 2.1.1 Introdução à energia solar

A crescente demanda por fontes de energia limpa e renovável tem impulsionado o interesse pela energia solar em todo o mundo. De acordo com VILLALVA (2015), a energia solar é uma das fontes mais promissoras para atender às necessidades energéticas futuras, devido à sua abundância e sustentabilidade. A capacidade instalada de energia solar tem apresentado um crescimento significativo nos últimos anos, atingindo cerda de 348 GW no mundo em 2022 (REN21, 2023). Como observado na Figura 1, no Brasil, a capacidade instalada de energia solar pode ser aproveitada de diversas formas, como através de sistemas fotovoltaicos para geração de eletricidade e sistemas de aquecimento solar para produção de calor (PINHO; GALDINO, 2014). Além disso, a energia solar apresenta vantagens significativas em relação a outras fontes de

energia, como a redução da dependência de combustíveis fósseis e a mitigação das emissões de gases de efeito estufa (PEREIRA *et al.*, 2017). Assim, compreender os princípios fundamentais da energia solar é essencial para explorar todo o seu potencial e promover sua utilização em larga escala.



Figura 1 – Evolução da Fonte Solar Fotovoltaica no Brasil

Fonte: Associação Brasileira de Energia Solar Fotovoltaica (2024).

#### 2.1.2 Conceitos fundamentais de irradiação solar

A irradiação solar é uma medida da quantidade de energia solar que atinge uma determinada área da superfície terrestre em um intervalo de tempo específico. Segundo Viana *et al.* (2011), a irradiação solar é expressa em unidades de energia por área, geralmente em Watt-hora por metro quadrado (Wh/m<sup>2</sup>) ou quilowatt-hora por metro quadrado (kWh/m<sup>2</sup>). É importante distinguir entre irradiação solar e irradiância solar, que é a taxa instantânea de energia solar incidente por unidade de área, expressa em Watts por metro quadrado (W/m<sup>2</sup>) (PEREIRA *et al.*, 2017). A irradiação solar varia ao longo do dia e do ano, dependendo de fatores como

a posição do Sol, a latitude, a altitude e as condições atmosféricas (DUFFIE; BECKMAN, 2013). Compreender esses conceitos é fundamental para avaliar o potencial de aproveitamento da energia solar em diferentes locais e períodos.

#### 2.1.3 Tipos de Irradiação Solar

A irradiação solar pode ser classificada em três tipos principais:

- Irradiação direta (ou radiação de feixe ou radiação de céu claro): é aquela que atinge a superfície terrestre diretamente do disco solar, sem sofrer espalhamento ou reflexão. Ela é mais intensa ao meio-dia e diminui à medida que o Sol se aproxima do horizonte.
- Irradiação difusa: é a radiação solar que é espalhada pelas moléculas dos gases atmosféricos e pelas partículas de poeira e nuvens, atingindo a superfície de forma indireta. Ela é mais uniforme durante o dia e pode ser significativa mesmo em dias nublados.
- Irradiação refletida (ou irradiação de albedo): é a parcela da radiação solar que é refletida por superfícies próximas (solo, água, estruturas) e atinge a superfície de interesse. A quantidade de radiação refletida depende da refletividade (albedo) da superfície.





Fonte: Adaptado de Grupo Quanta (2021).

A soma da irradiação direta e da irradiação difusa é conhecida como irradiação solar global, que representa a totalidade da radiação solar que atinge uma superfície horizontal (DUFFIE; BECKMAN, 2013).

#### 2.1.4 Fatores que influenciam a irradiação solar

Diversos fatores influenciam a quantidade de irradiação solar que atinge a superfície terrestre em um determinado local. Conforme explicado por PINHO e GALDINO (2014), esses fatores podem ser divididos em duas categorias principais: astronômicos e geográficos. Os fatores astronômicos incluem:

- Posição do Sol: A posição aparente do Sol no céu varia ao longo do dia e do ano, afetando o ângulo de incidência dos raios solares e, consequentemente, a intensidade da irradiação (DUFFIE; BECKMAN, 2013).
- Declinação solar A declinação solar é o ângulo entre o plano do equador terrestre e a linha que conecta o centro da Terra ao centro do Sol, variando ao longo do ano devido à inclinação do eixo de rotação da Terra (VILLALVA, 2015).

Os fatores geográficos incluem:

- Latitude: A latitude influencia a duração do dia e a altura do Sol no céu, afetando a quantidade de irradiação solar recebida (PEREIRA *et al.*, 2017).
- Altitude: A altitude afeta a espessura da atmosfera que os raios solares precisam atravessar, influenciando a atenuação da irradiação solar (VIANA *et al.*, 2011).
- Condições atmosféricas A presença de nuvens, aerossóis e vapor d'água na atmosfera pode absorver, refletir ou espalhar a radiação solar, reduzindo a irradiação que atinge a superfície (DUFFIE; BECKMAN, 2013).

Considerando esses fatores, é possível compreender as variações espaciais e temporais da irradiação solar e identificar os locais com maior potencial para o aproveitamento da energia solar. A combinação dos fatores astronômicos e geográficos resulta em diferentes níveis de irradiação solar em diferentes regiões do planeta. Por exemplo, locais próximos à linha do equador tendem a receber maiores níveis de irradiação solar ao longo do ano, devido à menor variação da posição do Sol e à menor influência da atmosfera (PEREIRA *et al.*, 2017). Já em latitudes mais altas, a irradiação solar tende a ser menor e mais variável, devido aos ângulos de incidência mais oblíquos e à maior influência das condições atmosféricas (DUFFIE; BECKMAN, 2013). Além disso, a irradiação solar também pode variar significativamente em escalas de tempo menores, como ao longo do dia e de acordo com as estações do ano. Essas variações são influenciadas principalmente pela posição do Sol e pelas condições atmosféricas, que podem mudar rapidamente (VIANA *et al.*, 2011). Compreender essas variações é fundamental para o dimensionamento e a operação eficiente de sistemas de energia solar, bem como para a previsão da geração de energia (PINHO; GALDINO, 2014).

Portanto, a análise dos fatores astronômicos e geográficos que influenciam a irradiação solar é essencial para a avaliação do potencial de aproveitamento da energia solar em diferentes locais e para a tomada de decisões relacionadas à instalação e ao gerenciamento de sistemas de energia solar. Essa análise deve levar em conta as variações espaciais e temporais da irradiação solar, bem como as características específicas de cada local, a fim de maximizar a eficiência e a viabilidade dos projetos de energia solar.



Figura 3 - Variação da irradiação solar média anual no Brasil

Fonte: Adaptado de Global Solar Atlas (2019).

#### 2.1.5 Importância da previsão da irradiação solar para sistemas de energia solar

A previsão da irradiação solar desempenha um papel crucial no planejamento, dimensionamento e operação de sistemas de energia solar. De acordo com Inman *et al.* (2013), a previsão precisa da irradiação solar permite otimizar o desempenho e a eficiência dos sistemas solares, além de facilitar sua integração à rede elétrica. No caso de sistemas fotovoltaicos, a previsão da irradiação solar auxilia na estimativa da geração de eletricidade, permitindo um melhor gerenciamento da demanda e do armazenamento de energia (VOYANT *et al.*, 2017). Já para sistemas de aquecimento solar, a previsão da irradiação solar é essencial para dimensionar adequadamente os coletores e os sistemas de armazenamento térmico (DUFFIE; BECKMAN, 2013). Além disso, a previsão da irradiação solar é fundamental para o planejamento e a programação da manutenção dos sistemas solares, evitando interrupções inesperadas e garantindo sua confiabilidade (PEREIRA *et al.*, 2017). No entanto, a previsão da irradiação solar apresenta desafios significativos, como a variabilidade da radiação solar e a necessidade de métodos precisos e confiáveis (DIAGNE *et al.*, 2013). Portanto, o desenvolvimento de métodos avançados de previsão da irradiação solar é essencial para impulsionar a adoção em larga escala da energia solar e maximizar seus benefícios.

#### 2.1.6 Métodos tradicionais de previsão da irradiação solar

Diversos métodos tradicionais têm sido utilizados para prever a irradiação solar, cada um com suas vantagens e limitações. Segundo Diagne *et al.* (2013), esses métodos podem ser classificados em três categorias principais: métodos estatísticos, métodos físicos e métodos híbridos. Os métodos estatísticos, como os modelos auto-regressivo integrado de médias móveis ou Autoregressive Integrated Moving Average Autoregressive Integrated Moving Average (ARIMA) e os modelos de suavização exponencial, baseiam-se na análise de séries temporais históricas para identificar padrões e tendências na irradiação solar (VOYANT *et al.*, 2017). Já os métodos físicos, como os modelos de transferência radiativa e os modelos de Previsão Numérica do Tempo (PNT), utilizam equações físicas e dados meteorológicos para simular a interação da radiação solar com a atmosfera (INMAN *et al.*, 2013). Os métodos híbridos, por sua vez, combinam abordagens estatísticas e físicas para aproveitar as vantagens de ambas (DIAGNE *et al.*, 2013). Embora esses métodos tradicionais tenham sido amplamente utilizados, eles apresentam limitações em termos de acurácia, generalização e capacidade de

lidar com a natureza não-linear e não-estacionária da irradiação solar, abrindo espaço para o desenvolvimento de técnicas mais avançadas, como as baseadas em aprendizado de máquina.

A energia solar tem um vasto potencial de aplicação em diferentes setores da economia. Na geração de energia elétrica, os sistemas fotovoltaicos podem ser instalados em residências, comércios, indústrias e usinas de grande porte, contribuindo para a diversificação da matriz energética e a redução da dependência de fontes fósseis (VILLALVA, 2015). No setor de transportes, a energia solar pode ser utilizada para carregar veículos elétricos, reduzindo as emissões de gases de efeito estufa (ISLAM *et al.*, 2013). Na agricultura, sistemas fotovoltaicos podem ser utilizados para bombear água, irrigar culturas e alimentar equipamentos agrícolas (CHANDEL *et al.*, 2015). Na indústria, a energia solar pode ser aproveitada para processos de aquecimento, refrigeração e produção de vapor, aumentando a eficiência energética e reduzindo custos (MEKHILEF *et al.*, 2011). Assim, a energia solar apresenta um enorme potencial para contribuir com o desenvolvimento sustentável e a mitigação das mudanças climáticas em escala global.

#### 2.2 Redes Neurais Artificiais e Aprendizado de Máquina

#### 2.2.1 Introdução às Redes Neurais Artificiais

As RNAs são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de aprender padrões complexos a partir de dados históricos (HAYKIN, 2009). Compostas por unidades de processamento interconectadas, chamadas de neurônios artificiais, as RNAs são capazes de aproximar funções não-lineares e resolver problemas de classificação, regressão e previsão (GOODFELLOW *et al.*, 2016).

Nas últimas décadas, as RNAs têm se destacado como uma das principais técnicas de aprendizado de máquina, devido à sua capacidade de modelar relações complexas entre variáveis de entrada e saída, sem a necessidade de especificar explicitamente as regras de mapeamento (SCHMIDHUBER, 2015). Essa característica torna as RNAs especialmente adequadas para lidar com problemas em que as relações entre as variáveis são desconhecidas ou difíceis de serem descritas matematicamente (LECUN *et al.*, 2015).

O processo de aprendizado das RNAs é baseado no ajuste dos pesos das conexões entre os neurônios, de forma a minimizar uma função de erro que mede a diferença entre as saídas produzidas pela rede e as saídas desejadas (GOODFELLOW *et al.*, 2016). Esse ajuste é

realizado de forma iterativa, utilizando algoritmos de otimização que atualizam os pesos da rede com base nos exemplos de treinamento apresentados (RUMELHART *et al.*, 1986).

Figura 4 – Representação de um neurônio artificial



Fonte: Adaptado de Vinicius (2017).

O neurônio artificial, também conhecido como perceptron, é a unidade básica de processamento em uma rede neural artificial. Ele é inspirado no funcionamento dos neurônios biológicos e é projetado para receber entradas, processar essas informações e produzir uma saída.

Com base na Figura 4, podemos identificar os seguintes componentes e funções do neurônio artificial:

Entradas ( $x_1$ ,  $x_2$ ,  $x_n$ ): O neurônio recebe informações de entrada através de múltiplos canais, representados pelas variáveis  $x_1$ ,  $x_2$ , e  $x_n$ . Essas entradas podem ser valores numéricos, características ou saídas de outros neurônios em uma rede neural.

Pesos ( $w_1$ ,  $w_2$ ,  $w_n$ ): Cada entrada está associada a um peso correspondente, representado pelas variáveis  $w_1$ ,  $w_2$  e  $w_n$ . Os pesos determinam a importância de cada entrada no processo de computação do neurônio. Eles são ajustados durante o treinamento da rede neural para aprender os padrões nos dados.

Combinação linear ( $\Sigma$ ): As entradas e seus pesos correspondentes são combinados por meio de uma operação de soma ponderada, representada pelo símbolo  $\Sigma$ . Cada entrada é multiplicada pelo seu peso e, em seguida, todos os produtos são somados. Essa operação pode ser expressa matematicamente como:

$$\sum = x_1 w_1 + x_2 w_2 + x_n w_n \tag{2.1}$$

Função de ativação ( $\varphi$ ): O resultado da combinação linear é passado através de uma função de ativação, representada por  $\varphi$  ou simplesmente g(.). A função de ativação introduz não-linearidade ao modelo e determina se o neurônio será ativado ou não, com base no valor de entrada. Existem várias funções de ativação comuns, como a função sigmóide, a tangente hiperbólica (tanh) e a unidade linear retificada (ReLU).

Saída: O resultado da função de ativação é a saída final do neurônio artificial. Essa saída pode ser um valor numérico, uma probabilidade ou uma classificação, dependendo da tarefa e da função de ativação utilizada.

O processo de computação em um neurônio artificial pode ser resumido da seguinte forma:

As entradas  $(x_1, x_2, x_n)$  são multiplicadas pelos pesos correspondentes  $(w_1, w_2, w_n)$ . Os produtos são somados na combinação linear  $(\Sigma)$ . O resultado da combinação linear é passado através da função de ativação  $(\varphi)$ . A saída da função de ativação é a saída final do neurônio. Em uma rede neural, múltiplos neurônios artificiais são organizados em camadas e interconectados, permitindo que a rede aprenda e modele padrões complexos nos dados. Os pesos são ajustados iterativamente através de um processo de treinamento, geralmente usando o algoritmo de retropropagação (backpropagation) e uma função de perda para medir o erro entre as saídas previstas e as saídas desejadas.

O neurônio artificial é a base fundamental para a construção de redes neurais artificiais, que são amplamente utilizadas em tarefas de aprendizado de máquina, como classificação, regressão e reconhecimento de padrões.

#### 2.2.2 Arquiteturas de RNAs

#### 2.2.2.1 Redes neurais feedforward

As redes neurais feedforward são a arquitetura mais simples e comum de RNAs, caracterizadas por um fluxo unidirecional de informação, desde a camada de entrada até a camada de saída, passando por uma ou mais camadas ocultas (HAYKIN, 2009). Nessa arquitetura, os neurônios de uma camada são conectados apenas aos neurônios da camada seguinte, sem conexões recorrentes ou de realimentação (GOODFELLOW *et al.*, 2016).

Um exemplo clássico de rede neural feedforward é o perceptron multicamadas ou do inglês, Multilayer Perceptron (MLP), que consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (ROSENBLATT, 1958). Cada neurônio da camada oculta e da camada de saída aplica uma função de ativação não-linear, como a função sigmoide ou a função ReLU (Rectified Linear Unit), sobre a soma ponderada das entradas recebidas (LECUN *et al.*, 2015).



Figura 5 – Estrutura de uma rede neural feedforward com duas camada oculta

As redes neurais feedforward têm sido amplamente aplicadas em problemas de classificação e regressão, como reconhecimento de imagens, processamento de linguagem natural e previsão de séries temporais (SCHMIDHUBER, 2015). Por exemplo, em um problema de reconhecimento de dígitos manuscritos, uma rede neural feedforward pode ser treinada para classificar imagens de dígitos em suas respectivas categorias (0-9), utilizando um conjunto de imagens rotuladas como exemplos de treinamento (LECUN *et al.*, 1998).

escondida

No entanto, a capacidade das redes feedforward de modelar dependências temporais é limitada, uma vez que não possuem memória interna para armazenar informações sobre os estados anteriores da rede (GOODFELLOW *et al.*, 2016). Para lidar com dados sequenciais, como séries temporais, é necessário utilizar arquiteturas de RNAs mais avançadas, como as redes neurais recorrentes.

Fonte: Adaptado de Palmiere (2016).

#### 2.2.2.2 Redes neurais recorrentes (RNNs)

As RNNs são uma classe de RNAs projetadas para lidar com dados sequenciais, como séries temporais e linguagem natural (RUMELHART *et al.*, 1986). Diferentemente das redes feedforward, as RNNs possuem conexões de realimentação, permitindo que a informação flua não apenas da entrada para a saída, mas também ao longo do tempo (GOODFELLOW *et al.*, 2016).

Nas RNNs, cada neurônio possui uma conexão recorrente consigo mesmo, permitindo que a informação seja propagada de um passo de tempo para o outro (HOCHREITER; SCHMIDHUBER, 1997). Essa característica confere às RNNs uma memória interna, capaz de armazenar informações sobre o contexto e as dependências de longo prazo presentes nos dados sequenciais (LECUN *et al.*, 2015).

Figura 6 – Arquitetura Básica da Célula RNN



Fonte: Adaptado de Dancker (2022).

Conforme a Figura 6, em cada passo de tempo, a RNN recebe uma entrada  $x_t$  e produz uma saída  $h_t$ , que é calculada com base na entrada atual e no estado oculto anterior  $h_{t-1}$ . A fórmula para atualizar o estado oculto é:

$$h_t = \tanh(W_{hh}h_{t-1} + W_{xh}x_t) \tag{2.2}$$

onde  $W_{hh}$  e  $W_{xh}$  são matrizes de pesos para as conexões recorrentes e de entrada, respectivamente, e tanh é a função de ativação tangente hiperbólica.

No entanto, o treinamento de RNNs tradicionais pode ser desafiador devido ao problema do desvanecimento do gradiente, que dificulta a propagação de informações relevantes ao longo do tempo (BENGIO *et al.*, 1994). Para superar essa limitação, foram desenvolvidas arquiteturas especializadas, como as redes Long Short-Term Memory (LSTM) e as redes Gated Recurrent Unit (GRU).

#### 2.2.2.2.1 Redes Long Short-Term Memory (LSTM)

As LSTMs foram introduzidas por Hochreiter e Schmidhuber (1997) para superar o problema do desvanecimento do gradiente nas RNNs. Elas possuem uma estrutura de porta que controla o fluxo de informações para dentro e para fora da célula de memória.



Figura 7 – Arquitetura Básica de uma Célula LSTM

Fonte: Adaptado de Dancker (2022).

A LSTM possui três portas: porta de entrada (*i*), porta de esquecimento (*f*) e porta de saída (*o*). Essas portas são calculadas usando a função sigmóide ( $\sigma$ ) e controlam a atualização do estado da célula (*c<sub>t</sub>*) e do estado oculto (*h<sub>t</sub>*). As equações para uma célula LSTM são:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$
  

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$
  

$$\tilde{c}t = \tanh(W_c \cdot [ht - 1, x_t] + b_c)$$
  
(2.3)

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}t$$
$$o_t = \sigma(W_o \cdot [ht - 1, x_t] + b_o)$$
$$h_t = o_t \odot \tanh(c_t)$$

(2.4)

onde  $W_f$ ,  $W_i$ ,  $W_c$  e  $W_o$  são matrizes de pesos,  $b_f$ ,  $b_i$ ,  $b_c$  e  $b_o$  são vetores de bias, e  $\odot$  denota a multiplicação elemento a elemento.

#### 2.2.2.2.2 Redes Gated Recurrent Unit (GRU)

As GRUs, propostas por Cho *et al.* (2014), são uma variante simplificada das LSTMs que mesclam a porta de esquecimento e a porta de entrada em uma única porta de atualização (z). Elas também possuem uma porta de redefinição (r) para controlar a quantidade de informação do estado anterior que é incorporada ao estado atual. As equações para uma célula GRU são:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$$
  

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$$
(2.5)

$$\tilde{h}t = \tanh(W \cdot [r_t \odot ht - 1, x_t])$$
$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

(2.6)

onde  $W_z$ ,  $W_r$  e W são matrizes de pesos



Figura 8 – Arquitetura Básica de uma Célula GRU

Fonte: Adaptado de Dancker (2022).

#### 2.2.2.3 Comparação entre RNN, LSTM e GRU

- 1. Complexidade do modelo:
  - RNNs: As RNNs básicas têm uma estrutura simples com uma única camada de neurônios recorrentes. Isso as torna mais fáceis de entender e implementar em comparação com as LSTMs e GRUs.
  - LSTMs: AsLSTMs têm uma estrutura mais complexa, com quatro camadas de interação em cada célula (porta de entrada, porta de esquecimento, porta de saída e estado da célula). Essa complexidade adicional permite que as LSTMs aprendam dependências de longo prazo de forma mais eficiente, mas também aumenta o número de parâmetros e o custo computacional do modelo (HOCHREITER; SCHMIDHUBER, 1997)
  - GRUs: As GRUs simplificam a estrutura dasLSTMs, mesclando a porta de entrada e a porta de esquecimento em uma única porta de atualização. Elas também removem o estado da célula separado. Essa simplificação reduz o número de parâmetros e o custo computacional em comparação com as LSTMs, mantendo um desempenho

similar em muitas tarefas (CHUNG et al., 2014).

- 2. Desempenho em diferentes tarefas:
  - RNNs: As RNNs básicas podem lidar com tarefas simples que não requerem a captura de dependências de longo prazo, como modelagem de linguagem a curto prazo e reconhecimento de fala com contexto limitado (MIKOLOV *et al.*, 2010).
  - LSTMs: As LSTMs se destacam em tarefas que requerem a captura de dependências de longo prazo, como modelagem de linguagem a longo prazo, tradução automática e reconhecimento de fala com contexto mais amplo (SUTSKEVER *et al.*, 2014).
  - GRUs: As GRUs têm desempenho comparável às LSTMs em muitas tarefas, como modelagem de linguagem, tradução automática e classificação de sentimento (CHUNG *et al.*, 2014). Elas podem ser uma boa escolha quando se deseja um equilíbrio entre desempenho e eficiência computacional.
- 3. Recursos computacionais e tempo de treinamento:
  - RNNs: As RNNs básicas têm menor custo computacional e geralmente são mais rápidas para treinar em comparação com as LSTMs e GRUs, devido à sua estrutura mais simples (MIKOLOV *et al.*, 2010).
  - LSTMs: As LSTMs têm mais parâmetros e requerem mais recursos computacionais para treinar e inferir em comparação com as RNNs básicas e GRUs. Isso pode levar a tempos de treinamento mais longos e maior consumo de memória (HOCHREITER; SCHMIDHUBER, 1997).
  - GRUs: As GRUs são mais eficientes computacionalmente do que as LSTMs, devido à sua estrutura simplificada. Elas podem alcançar tempos de treinamento mais rápidos e menor consumo de memória, mantendo um desempenho comparável em muitas tarefas (CHUNG *et al.*, 2014).

#### 2.2.3 Treinamento de RNAs

#### 2.2.3.1 Aprendizado supervisionado

O treinamento das RNAs é realizado por meio de um processo de aprendizado supervisionado, no qual a rede é apresentada a um conjunto de exemplos rotulados, contendo pares de entrada e saída desejada (GOODFELLOW *et al.*, 2016). O objetivo do treinamento é ajustar os pesos das conexões entre os neurônios, de forma a minimizar uma função de erro que

mede a diferença entre as saídas produzidas pela rede e as saídas desejadas (HAYKIN, 2009).

No aprendizado supervisionado, os exemplos de treinamento são apresentados à rede de forma iterativa, e os pesos são atualizados a cada iteração, utilizando algoritmos de otimização baseados no gradiente descendente (RUMELHART *et al.*, 1986). O algoritmo mais comum para o treinamento de RNAs é o backpropagation, que propaga o erro da camada de saída para as camadas anteriores, ajustando os pesos de forma a minimizar o erro (LECUN *et al.*, 2015)

O processo de treinamento de RNAs envolve várias etapas, como a inicialização dos pesos, a normalização dos dados de entrada, a escolha da função de ativação e da função de erro, e a definição dos hiperparâmetros, como a taxa de aprendizado e o número de épocas de treinamento (GOODFELLOW *et al.*, 2016). A escolha adequada desses elementos é crucial para o desempenho e a generalização do modelo (BENGIO, 2012).

2.2.3.1.1 Inicialização dos pesos

A inicialização dos pesos é a primeira etapa do treinamento de RNAs. Os pesos das conexões entre os neurônios são inicializados com valores aleatórios, geralmente pequenos, próximos de zero (GOODFELLOW *et al.*, 2016). A inicialização adequada dos pesos é importante para evitar problemas como a saturação dos neurônios e para facilitar a convergência do modelo durante o treinamento (GLOROT; BENGIO, 2010).

- Inicialização aleatória uniforme: Na inicialização aleatória uniforme, os pesos são inicializados com valores aleatórios amostrados de uma distribuição uniforme dentro de um intervalo específico. Geralmente, o intervalo é simétrico em torno de zero, como [-a, a], onde a é um valor pequeno, como 0.01 ou 0.05 ((GOODFELLOW et al., 2016). Essa abordagem é simples de implementar, mas pode levar a problemas de saturação dos neurônios quando os pesos são muito grandes ou muito pequenos (GLOROT; BENGIO, 2010).
- Inicialização aleatória normal: Na inicialização aleatória normal, os pesos são inicializados com valores aleatórios amostrados de uma distribuição normal (Gaussiana) com média zero e um desvio padrão específico. O desvio padrão é geralmente escolhido como um valor pequeno, como 0.01 ou  $\frac{1}{\sqrt{n}}$ , onde *n* é o número de entradas do neurônio (LECUN *et al.*, 2012). Essa abordagem pode ajudar a evitar a saturação dos neurônios, pois a maioria dos pesos estará concentrada em torno de zero (GOODFELLOW *et al.*, 2016).
- Inicialização Xavier (Glorot): A inicialização Xavier, também conhecida como inici-

alização Glorot, foi proposta por Xavier Glorot e Yoshua Bengio em 2010 (GLOROT; BENGIO, 2010). Ela é projetada para manter a variância dos sinais de entrada e saída aproximadamente igual em todas as camadas da rede. Os pesos são inicializados com valores aleatórios amostrados de uma distribuição uniforme com limites específicos, calculados com base no número de entradas e saídas do neurônio:

$$W \sim U\left[-\frac{\sqrt{6}}{\sqrt{n_i + n_o}}, \frac{\sqrt{6}}{\sqrt{n_i + n_o}}\right]$$
(2.7)

Onde *W* são os pesos, *U* é a distribuição uniforme,  $n_i$  é o número de entradas do neurônio e  $n_o$  é o número de saídas do neurônio. Essa abordagem é eficaz para redes com funções de ativação simétricas em torno de zero, como a tangente hiperbólica (tanh) (GLOROT; BENGIO, 2010).

 Inicialização He: A inicialização He, proposta por Kaiming He e colaboradores em 2015, é uma extensão da inicialização Xavier para lidar com funções de ativação não-simétricas, como a unidade linear retificada (ReLU) (HE *et al.*, 2015). Os pesos são inicializados com valores aleatórios amostrados de uma distribuição normal com média zero e desvio padrão específico, calculado com base no número de entradas do neurônio:

$$W \sim N\left(0, \sqrt{\frac{2}{n_i}}\right) \tag{2.8}$$

Onde *W* são os pesos, *N* é a distribuição normal e  $n_i$  é o número de entradas do neurônio. Essa abordagem é eficaz para redes com funções de ativação ReLU, pois leva em consideração a não-linearidade da função de ativação (HE *et al.*, 2015).

A escolha da estratégia de inicialização dos pesos depende da arquitetura da rede, da função de ativação utilizada e do problema em questão. Em geral, a inicialização Xavier é uma boa escolha para redes com funções de ativação simétricas, enquanto a inicialização He é mais adequada para redes com funções de ativação ReLU (GOODFELLOW *et al.*, 2016). No entanto, é importante experimentar diferentes estratégias e ajustar os hiperparâmetros para obter o melhor desempenho para um problema específico.

#### 2.2.3.1.2 Normalização dos dados de entrada

A normalização dos dados de entrada é uma etapa de pré-processamento que visa ajustar a escala dos valores de entrada para um intervalo adequado, geralmente entre 0 e 1

ou entre -1 e 1 (IOFFE; SZEGEDY, 2015). Essa etapa é importante para evitar que certas características dominem o processo de aprendizado devido à sua escala maior em relação às outras (LECUN *et al.*, 2012).

Existem diferentes técnicas de normalização:

 Normalização Min-Max: A normalização min-max, também conhecida como normalização de escala, é uma técnica simples que redimensiona os valores de entrada para um intervalo específico, geralmente entre 0 e 1. A fórmula para a normalização min-max é:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{2.9}$$

Onde x é o valor original,  $x_{min}$  e  $x_{max}$  são os valores mínimo e máximo da característica, respectivamente, e  $x_{norm}$  é o valor normalizado. Essa técnica é fácil de implementar e pode ser útil quando os limites dos dados são conhecidos e bem definidos (JAYALAKSHMI; SANTHAKUMARAN, 2011). No entanto, ela é sensível a outliers e pode não ser adequada para casos em que os dados têm uma distribuição muito assimétrica.

 Normalização Z-Score: A normalização z-score, também conhecida como padronização, é uma técnica que redimensiona os dados para que tenham média zero e desvio padrão unitário. A fórmula para a normalização z-score é:

$$x_{norm} = \frac{x - \mu}{\sigma} \tag{2.10}$$

Onde *x* é o valor original,  $\mu$  é a média da característica,  $\sigma$  é o desvio padrão da característica e  $x_{norm}$  é o valor normalizado. Essa técnica é útil quando os dados têm uma distribuição aproximadamente normal e não há outliers significativos (JAYALAKSHMI; SANTHAKUMARAN, 2011). A normalização z-score é amplamente utilizada e pode ajudar a acelerar a convergência do modelo durante o treinamento (LECUN *et al.*, 2012).

 Normalização de Batch: A normalização de batch é uma técnica de normalização aplicada durante o treinamento da rede neural, em vez de ser realizada como uma etapa de préprocessamento (IOFFE; SZEGEDY, 2015). Ela normaliza os valores de entrada de cada batch (subconjunto de exemplos de treinamento) para que tenham média zero e desvio padrão unitário. A fórmula para a normalização de batch é:

$$x_{norm} = \frac{x - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}}$$
(2.11)

Onde x é o valor original,  $\mu_B$  é a média do batch,  $\sigma_B^2$  é a variância do batch,  $\varepsilon$  é um pequeno valor adicionado para evitar divisão por zero e  $x_{norm}$  é o valor normalizado.

A normalização de batch é eficaz para acelerar a convergência do modelo e reduzir a sensibilidade à inicialização dos pesos (IOFFE; SZEGEDY, 2015). Além disso, ela pode atuar como um regularizador, reduzindo o overfitting (GOODFELLOW *et al.*, 2016).

2.2.3.1.3 Escolha da função de ativação

A função de ativação é responsável por introduzir não-linearidade na rede, permitindo que ela aprenda relações complexas entre as entradas e as saídas (LECUN *et al.*, 2015). A escolha da função de ativação depende da natureza do problema e da arquitetura da rede (GOODFELLOW *et al.*, 2016).

Algumas das funções de ativação mais comuns incluem a função sigmóide, a tangente hiperbólica (tanh) e a unidade linear retificada (ReLU) (NAIR; HINTON, 2010).

#### • Função Sigmóide:

A função sigmóide é uma função não-linear que mapeia a entrada para um valor entre 0 e 1. Ela é definida pela seguinte fórmula:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{2.12}$$

Onde *x* é a entrada da função. A função sigmóide tem uma forma característica em "S", com uma região central de transição suave entre os valores baixos e altos. Ela é comumente usada em redes neurais para introduzir não-linearidade e modelar probabilidades. No entanto, a função sigmóide pode sofrer do problema do desvanecimento do gradiente, especialmente em redes profundas, devido à sua saturação nos extremos (GOODFELLOW *et al.*, 2016).

• **Tangente Hiperbólica (tanh)**: A função tangente hiperbólica é outra função não-linear semelhante à sigmóide, mas com uma faixa de saída entre -1 e 1. Sua fórmula é dada por:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$
(2.13)

Onde x é a entrada da função. A tanh tem uma forma semelhante à sigmóide, mas é centralizada em zero. Ela também pode sofrer do problema do desvanecimento do gradiente, embora seja menos propenso a isso em comparação com a sigmóide (LECUN *et al.*, 2012).

• Unidade Linear Retificada (ReLU): A ReLU é uma função de ativação não-linear que tem se mostrado eficaz em redes profundas. Ela é definida pela seguinte fórmula:

$$\operatorname{ReLU}(x) = \max(0, x) \tag{2.14}$$

Onde *x* é a entrada da função. A ReLU retorna 0 para entradas negativas e a própria entrada para valores positivos, introduzindo uma não-linearidade simples, mas eficaz. Ela evita o problema do desvanecimento do gradiente, pois seu gradiente é sempre 0 ou 1, permitindo que o gradiente flua facilmente através da rede (NAIR; HINTON, 2010). Além disso, a ReLU é computacionalmente eficiente, pois requer apenas uma comparação e uma multiplicação. No entanto, a ReLU pode sofrer do problema da "morte" de neurônios, quando muitas entradas negativas levam um neurônio a nunca ativar e ficar "preso"em zero (GLOROT *et al.*, 2011).

Existem diversas funções de ativação amplamente empregadas em redes neurais, cada uma com atributos distintos e implicações específicas. A seleção da função a ser utilizada é determinada pela arquitetura da rede, natureza do problema a ser resolvido e recursos computacionais disponíveis. Em geral, a função ReLU tem demonstrado eficácia em redes profundas, enquanto a sigmoide e a tangente hiperbólica ainda encontram aplicação em contextos específicos, como em redes recorrentes (GOODFELLOW *et al.*, 2016)

2.2.3.1.4 Escolha da função de erro

A função de erro, também conhecida como função de perda ou função de custo, mede a diferença entre as saídas produzidas pela rede e as saídas desejadas (GOODFELLOW *et al.*, 2016). O objetivo do treinamento é minimizar essa função de erro, ajustando os pesos da rede (HAYKIN, 2009).

Algumas das funções de erro comuns incluem o erro quadrático médio (MSE), a entropia cruzada e a divergência de Kullback-Leibler (KL) (GOODFELLOW *et al.*, 2016). A escolha da função de erro depende do tipo de problema (regressão ou classificação) e da distribuição dos dados (JANOCHA; CZARNECKI, 2017).

#### 2.2.3.1.5 Definição dos hiperparâmetros

Os hiperparâmetros são parâmetros que não são aprendidos durante o treinamento, mas são definidos antes do início do processo (GOODFELLOW *et al.*, 2016). Portanto a escolha adequada dos hiperparâmetros é crucial para o desempenho e a generalização do modelo (BENGIO, 2012).

Alguns dos hiperparâmetros mais importantes incluem:

• Taxa de aprendizado(learning rate): controla o tamanho dos ajustes nos pesos a cada

iteração (BENGIO, 2012). Uma taxa de aprendizado muito baixa pode tornar o treinamento muito lento, enquanto uma taxa muito alta pode levar à oscilação em torno do mínimo da função de erro (GOODFELLOW *et al.*, 2016).

- Número de épocas: define o número de vezes que o conjunto de treinamento é apresentado à rede durante o treinamento (HAYKIN, 2009). Um número insuficiente de épocas pode levar a um subajuste (underfitting), enquanto um número excessivo pode causar sobreajuste (overfitting) (GOODFELLOW *et al.*, 2016).
- Tamanho do lote (batch size): define o número de exemplos de treinamento utilizados em cada iteração para atualizar os pesos (BENGIO, 2012). O uso de lotes permite uma melhor estimativa do gradiente e pode acelerar o treinamento (GOODFELLOW *et al.*, 2016)
- Momentum: O momentum é uma técnica que ajuda a acelerar o treinamento de redes neurais e a melhorar a convergência do modelo. Ele atua como um mecanismo de "amortecimento" que reduz a oscilação do gradiente durante a atualização dos pesos (QIAN, 1999). A ideia por trás do momentum é adicionar uma fração do vetor de atualização anterior ao vetor de atualização atual, de forma que a atualização dos pesos leve em consideração não apenas o gradiente atual, mas também a "direção" das atualizações anteriores. A fórmula para a atualização dos pesos com momentum é:

$$v_t = \gamma v_{t-1} + \eta \nabla_{\theta} J(\theta) \tag{2.15}$$

$$\theta = \theta - v_t \tag{2.16}$$

Onde  $v_t$  é o vetor de velocidade (momentum) no tempo t,  $\gamma$  é a taxa de momentum (geralmente entre 0,9 e 0,99),  $\eta$  é a taxa de aprendizado,  $\nabla_{\theta} J(\theta)$  é o gradiente da função de custo em relação aos parâmetros  $\theta$ , e  $\theta$  são os pesos da rede.

O momentum ajuda a suavizar as oscilações do gradiente e permite que o modelo "salte"sobre mínimos locais rasos, acelerando a convergência para um mínimo global (ou um mínimo local melhor) (SUTSKEVER *et al.*, 2013). No entanto, é importante ajustar a taxa de momentum adequadamente, pois valores muito altos podem levar a overshooting e instabilidade no treinamento.

• **Dropout**: O dropout é uma técnica de regularização que ajuda a reduzir o overfitting em redes neurais, especialmente em modelos com um grande número de parâmetros

(SRIVASTAVA *et al.*, 2014). A ideia principal do dropout é "desligar"aleatoriamente uma fração dos neurônios durante o treinamento, de forma a evitar que a rede se torne excessivamente dependente de neurônios específicos. Durante o treinamento com dropout, em cada iteração (ou mini-batch), uma fração *p* dos neurônios em cada camada é aleatoriamente "desligada", ou seja, sua saída é definida como zero. Isso força a rede a aprender recursos mais robustos e menos interdependentes, pois não pode confiar em neurônios específicos estarem sempre presentes (SRIVASTAVA *et al.*, 2014).

Na fase de teste (ou inferência), todos os neurônios são mantidos ativos, mas suas saídas são multiplicadas por p para compensar o fato de que mais neurônios estão ativos em comparação com o treinamento. Isso pode ser visto como uma forma de averaging de modelos, onde cada subconjunto de neurônios representa um modelo diferente (SRIVASTAVA *et al.*, 2014).

O dropout é controlado por um hiperparâmetro p, que representa a probabilidade de um neurônio ser mantido ativo durante o treinamento. Valores típicos de p variam entre 0,5 e 0,8, dependendo do tamanho da rede e da quantidade de dados de treinamento disponíveis (SRIVASTAVA *et al.*, 2014). Valores mais altos de p levam a uma regularização mais forte, mas podem exigir um treinamento mais longo para convergir.

Outros hiperparâmetros incluem a taxa de decaimento de peso (weight decay). A escolha dos hiperparâmetros pode ser feita manualmente, com base em heurísticas e experiência prévia, ou por meio de técnicas de busca automática, como a busca em grade (grid search) e a otimização bayesiana (BERGSTRA *et al.*, 2011).

O processo de treinamento de RNAs envolve várias etapas importantes, como a inicialização dos pesos, a normalização dos dados de entrada, a escolha da função de ativação e da função de erro, e a definição dos hiperparâmetros. Cada uma dessas etapas requer cuidadosa consideração e ajuste para garantir o bom desempenho e a generalização do modelo. A compreensão aprofundada dessas etapas é fundamental para o desenvolvimento de eficazes e robustas.

#### 2.2.3.2 Técnicas de regularização

Durante o treinamento de RNAs, é comum encontrar problemas como o sobreajuste (overfitting), onde o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar para novos dados (GOODFELLOW *et al.*, 2016). Para mitigar esse

problema, são utilizadas técnicas de regularização, que visam controlar a complexidade do modelo e melhorar sua capacidade de generalização (KUKAčKA *et al.*, 2017)

Algumas das técnicas de regularização mais comuns incluem:

- Regularização L1 e L2: adicionam um termo de penalização à função de erro, baseado na norma L1 ou L2 dos pesos da rede (NG, 2004). Isso encoraja a rede a aprender pesos menores e mais distribuídos, reduzindo a complexidade do modelo (GOODFELLOW *et al.*, 2016).
- **Parada antecipada (early stopping)**: interrompe o treinamento quando o desempenho no conjunto de validação começa a se deteriorar, evitando que o modelo se ajuste excessivamente aos dados de treinamento (PRECHELT, 1998). Isso requer o monitoramento do desempenho em um conjunto de dados separado durante o treinamento (GOODFELLOW *et al.*, 2016).
- Aumento de dados (data augmentation) Aumento de dados (data augmentation): aplica transformações aos dados de treinamento, como rotações, translações e escala, para gerar exemplos adicionais e aumentar a variabilidade do conjunto de treinamento (SIMARD *et al.*, 2003). Isso melhora a capacidade de generalização do modelo e reduz o sobreajuste (PEREZ; WANG, 2017).

Escolher uma técnica ou outra de regularização depende da arquitetura da rede, do tamanho do conjunto de treinamento e da complexidade do problema. É comum combinar múltiplas técnicas de regularização para obter melhores resultados (KUKAčKA *et al.*, 2017).

### 2.2.3.3 Algoritmos de treinamento

Os algoritmos de treinamento desempenham um papel crucial no ajuste dos pesos das RNAs, buscando minimizar uma função de perda que mede a diferença entre as previsões do modelo e os valores reais ((GOODFELLOW *et al.*, 2016). Alguns dos algoritmos mais populares são:

 Stochastic Gradient Descent (SGD) : O SGD atualiza os pesos da rede utilizando o gradiente calculado a partir de um subconjunto aleatório dos exemplos de treinamento, chamado de mini-batch (BOTTOU, 2010). A atualização dos pesos é realizada após cada mini-batch, de acordo com a seguinte fórmula:

$$w_{t+1} = w_t - \eta \cdot \nabla_w L(w_t) \tag{2.17}$$

onde  $w_t$  é o vetor de pesos no tempo t,  $\eta$  é a taxa de aprendizado e  $\nabla_w L(w_t)$  é o gradiente da função de perda em relação aos pesos.

2. Adaptive Moment Estimation (Adam): O Adam combina as vantagens do SGD e do RMSprop, adaptando as taxas de aprendizado para cada parâmetro com base nas estimativas dos momentos do gradiente (KINGMA; BA, 2017). As equações de atualização dos pesos são:

$$m_{t} = \beta_{1} \cdot m_{t-1} + (1 - \beta_{1}) \cdot \nabla_{w} L(w_{t})$$

$$v_{t} = \beta_{2} \cdot v_{t-1} + (1 - \beta_{2}) \cdot (\nabla_{w} L(w_{t}))^{2}$$

$$\hat{m}_{t} = \frac{m_{t}}{1 - \beta_{1}^{t}}$$

$$\hat{v}_{t} = \frac{v_{t}}{1 - \beta_{2}^{t}}$$

$$wt + 1 = w_{t} - \frac{\eta}{\sqrt{\hat{v}_{t}} + \varepsilon} \cdot \hat{m}_{t}$$

$$(2.18)$$

onde  $m_t$  e  $v_t$  são as estimativas do primeiro e segundo momentos do gradiente,  $\beta_1$  e  $\beta_2$  são hiperparâmetros de decaimento exponencial, e  $\varepsilon$  é um pequeno valor para evitar divisão por zero.

3. RMSprop: O RMSprop ajusta a taxa de aprendizado para cada parâmetro, dividindo a taxa de aprendizado pela média móvel exponencial do quadrado dos gradientes recentes (TIELEMAN; HINTON, 2012). A atualização dos pesos é dada por:

$$v_t = \beta \cdot v_{t-1} + (1 - \beta) \cdot (\nabla_w L(w_t))^2$$
$$w_{t+1} = w_t - \frac{\eta}{\sqrt{v_t} + \varepsilon} \cdot \nabla_w L(w_t)$$
(2.19)

onde  $v_t$  é a média móvel exponencial do quadrado dos gradientes,  $\beta$  é um hiperparâmetro de decaimento exponencial, e  $\varepsilon$  é um pequeno valor para evitar divisão por zero. A escolha do algoritmo de treinamento deve levar em consideração as características do problema, o tamanho do conjunto de dados e os recursos computacionais disponíveis (GOODFELLOW *et al.*, 2016). Algoritmos adaptativos como o Adam e o RMSprop têm apresentado bom desempenho em uma ampla gama de aplicações (RUDER, 2017).

#### 2.2.3.4 Métricas de avaliação de desempenho de modelos de previsão

A avaliação do desempenho dos modelos de previsão é essencial para comparar diferentes abordagens e selecionar o modelo mais adequado para uma determinada aplicação (HYNDMAN; ATHANASOPOULOS, 2018). Algumas das métricas mais comuns para avaliar o desempenho de modelos de previsão de séries temporais incluem:

Mean Absolute Error (MAE): O MAE mede a média dos erros absolutos entre os valores previstos e os valores reais, fornecendo uma medida da magnitude média dos erros (HYNDMAN; KOEHLER, 2006). A fórmula para calcular o MAE é:

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
(2.20)

onde *n* é o número de observações,  $y_i$  é o valor real e  $\hat{y}_i$  é o valor previsto.

 Mean Squared Error (MSE): calcula a média dos erros quadráticos entre os valores previstos e os valores reais, penalizando erros maiores. Quanto menor o valor do MSE, melhor o desempenho do modelo. A fórmula para calcular o MSE é:

$$MSE = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$
(2.21)

 Root Mean Squared Error (RMSE): O RMSE calcula a raiz quadrada da média dos erros quadráticos entre os valores previstos e os valores reais, penalizando erros maiores (CHAI; DRAXLER, 2014). A fórmula para calcular o RMSE é:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
(2.22)

onde *n* é o número de observações,  $y_i$  é o valor real e  $\hat{y}_i$  é o valor previsto.

 Mean Absolute Percentage Error (MAPE): O MAPE expressa o erro como uma porcentagem do valor real, fornecendo uma medida relativa do erro (KIM; KIM, 2016). A fórmula para calcular o MAPE é:

$$MAPE = \frac{100}{n} \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$
(2.23)

onde *n* é o número de observações,  $y_i$  é o valor real e  $\hat{y}_i$  é o valor previsto.

Coefficient of Determination (R<sup>2</sup>): O R<sup>2</sup> mede a proporção da variância nos dados que é explicada pelo modelo, indicando a qualidade do ajuste (ALEXANDER *et al.*, 2015). A fórmula para calcular o R<sup>2</sup> é:

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \bar{y})^{2}}$$
(2.24)

onde *n* é o número de observações,  $y_i$  é o valor real,  $\hat{y}_i$  é o valor previsto e  $\bar{y}$  é a média dos valores reais.

Além dessas métricas, outras medidas específicas para a previsão de irradiação solar têm sido propostas, como o Forecast Skill e o Relative Root Mean Squared Error (rRMSE), que levam em conta a variabilidade inerente à irradiação solar (YANG *et al.*, 2020).

#### 2.3 Aplicação de Redes Neurais Recorrentes na Previsão de Irradiação Solar

#### 2.3.1 Estado da Arte na Previsão de Irradiação Solar com RNNs

A previsão de irradiação solar tem ganhado cada vez mais importância devido à crescente participação da energia solar fotovoltaica na matriz energética. Nesse contexto, as Redes Neurais Recorrentes (RNNs) têm se destacado como uma abordagem promissora para essa finalidade (VOYANT *et al.*, 2017). Nos últimos anos, diversos estudos têm explorado a aplicação de RNNs na previsão de irradiação solar, utilizando diferentes arquiteturas, estratégias de treinamento e conjuntos de dados (WANG *et al.*, 2016).

Um dos principais desafios na previsão de irradiação solar é lidar com a natureza variável e intermitente da energia solar, que é influenciada por fatores como a posição do sol, condições atmosféricas e sazonalidade (INMAN *et al.*, 2013). As RNNs são capazes de capturar dependências temporais de longo prazo nos dados históricos de irradiação solar, o que as torna especialmente adequadas para essa tarefa (QING; NIU, 2018).

Diversos estudos têm demonstrado a eficácia das RNNs na previsão de irradiação solar em diferentes contextos e aplicações práticas. Por exemplo, Qing e Niu (2018) utilizaram uma RNN do tipo LSTM para prever a irradiação solar horária com base em dados meteorológicos e de irradiação histórica. Os resultados mostraram que a LSTM superou outros modelos de referência, como redes neurais feedforward e modelos de persistência, em termos de precisão e capacidade de capturar a variabilidade da irradiação solar.

Em outro estudo, (ALZAHRANI *et al.*, 2017) propuseram um modelo híbrido que combina uma RNN do tipo LSTM com um algoritmo de otimização de enxame de partículas para prever a irradiação solar global em intervalos de 5 minutos, 1 hora e 1 dia na Arábia Saudita. O modelo híbrido apresentou um desempenho superior em comparação com modelos individuais de LSTM e outros modelos de aprendizado de máquina, como máquinas de vetores de suporte e florestas aleatórias.

O trabalho de Brahma e Wadhvani (2020) utiliza dados multilocalização para aprimorar a precisão das previsões, aplicando metodologias de deep learning, como LSTM bidirecional e mecanismos de atenção, para capturar padrões complexos nos dados históricos de irradiação solar.

Já no estudo de Urzagasti *et al.* (2021) compararam a acurácia de modelos de RNNs utilizando diferentes conjuntos de dados e horizontes de previsão, destacando a influência de variáveis meteorológicas e o tamanho do dataset na precisão dos modelos. A análise mostrou que, embora as RNNs apresentem desempenho superior, fatores externos como a escolha das variáveis de entrada são cruciais para a precisão do modelo. Além disso, a pesquisa evidenciou que a precisão da previsão diminui à medida que o horizonte de previsão aumenta, um desafio comum na previsão de séries temporais que requer abordagens inovadoras em termos de seleção de características e estruturação de modelos.

A previsão de irradiação solar utilizando Redes Neurais Recorrentes representa uma área de pesquisa com potencial transformador para a energia solar fotovoltaica. Os estudos revisados destacam não apenas a eficácia das RNNs em abordar a complexidade dos dados de irradiação solar, mas também a importância da escolha de arquiteturas, técnicas avançadas e a consideração de variáveis externas na construção de modelos precisos. À medida que as técnicas de deep learning evoluem, espera-se que a previsão de irradiação solar se torne cada vez mais precisa e confiável, contribuindo para a otimização da geração e utilização da energia solar..

#### **3 METODOLOGIA**

Este capítulo descreve a metodologia adotada no presente estudo para o desenvolvimento de modelos de previsão de irradiação solar de médio prazo utilizando redes neurais recorrentes do tipo LSTM (Long Short-Term Memory). O processo metodológico envolveu diversas etapas, conforme ilustrado no fluxograma da Figura 9.





Fonte: Elaborado pelo autor.

Inicialmente, os dados de irradiação solar foram coletados por uma estação meteorológica localizada no Campus das Auroras da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), no município de Redenção, Ceará. Em seguida, esses dados passaram por um processo de pré-processamento, envolvendo a conversão de formato, tratamento de valores faltantes e agregação temporal.

Após o pré-processamento, foram implementados diferentes modelos de redes neurais recorrentes do tipo LSTM, com variações na arquitetura e nos hiperparâmetros. Esses modelos foram então treinados e testados utilizando os dados pré-processados, sendo avaliados por meio de métricas como o Erro Quadrático Médio (MSE) e o Erro Absoluto Médio (MAE).

As seções a seguir detalham cada uma das etapas mencionadas, fornecendo informações sobre os procedimentos adotados, os desafios encontrados e as soluções propostas.

#### 3.1 Coleta de Dados

Os dados usados neste estudo foram coletados por uma estação meteorológica localizada no Campus das Auroras da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) no município de Redenção, Ceará. A estação está equipada com um datalogger CR300, responsável por registrar diversos parâmetros meteorológicos a cada minuto, incluindo irradiação solar global (GHI), irradiação solar difusa (DHI), irradiação solar direta (DNI), temperatura, umidade, velocidade do vento, entre outros.

O período de coleta de dados se estendeu de dezembro de 2020 a setembro de 2022. Para transferir os dados do *datalogger* para um computador, foi estabelecida uma conexão USB entre o equipamento e um notebook, usando o software PC400 fornecido pela empresa responsável pela instalação da estação. O processo de coleta de dados durou aproximadamente duas horas. A Figura 10 apresenta a estação meteorológica e algumas etapas do processo de coleta de dados. Onde: (1) Estação meteorológica instalada no Campus das Auroras da UNILAB em Redenção-CE. (2) e (3) Detalhes dos sensores e do datalogger CR300. (4) Transferência dos dados coletados do datalogger para um notebook usando o software PC400 via conexão USB.

Figura 10 – Setup da estação meteorológica e processo de coleta de dados.



Fonte: Elaborado pelo autor.

#### 3.2 Pré-processamento de Dados

Esta seção aborda sobre como foi realizada o pré-processamento dos dados utilizados para este estudo. A Figura 11 mostra o passo a posso seguido.



Figura 11 - Fluxograma do Pré-processamento dos Dados.

Fonte: Elaborado pelo autor.

Após a coleta, os dados armazenados inicialmente em um arquivo .dat foram convertidos para o formato CSV usando a linguagem Python, com as colunas separadas por ponto e vírgula. Como o foco deste estudo é a irradiação solar, foi dada atenção especial à coluna GHI (irradiação solar global). Durante a análise exploratória dos dados, foram observados valores negativos na coluna GHI, os quais foram substituídos por zero, uma vez que esses valores ocorreram durante as primeiras horas da manhã (entre 1h e 4h), período em que a irradiação solar é praticamente nula.

Em seguida, os dados foram agregados de minutos para horas, calculando-se a média

dos valores de irradiação para cada intervalo de uma hora. Após essa etapa, foi verificada a existência de lacunas (dados faltantes) no conjunto de dados. Para encontrar o período contínuo mais longo sem lacunas, foi identificado o intervalo de dezembro de 2020 a maio de 2022, correspondendo a mais da metade do conjunto de dados total (dezembro de 2020 a abril de 2023). Optou-se por adicionar também os dados de junho a setembro de 2022, apesar da presença de algumas lacunas, resultando em um conjunto de dados final abrangendo o período de 04/12/2020 a 30/09/2022. O conjunto de dados pré-processados foi dividido em dois subconjuntos: um para treinamento e outro para teste. O período de 04/12/2020 a 23/09/2022 foi utilizado para treinar os modelos LSTM, abrangendo diferentes estações do ano e condições climáticas. Já o período de 24/09/2022 a 30/09/2022 foi reservado para testar o desempenho dos modelos treinados na previsão de irradiação solar de médio prazo. A Figura 12 ilustra como foi realizada esta divisão dos dados.





Fonte: Elaborado pelo autor.

Os dados de treinamento foram usados para ajustar os parâmetros dos modelos LSTM, enquanto os dados de teste serão utilizados para avaliar a capacidade de generalização dos modelos em dados não vistos durante o treinamento. Esse processo de divisão dos dados em conjuntos de treinamento e teste é essencial para evitar o *overfitting* e obter uma estimativa mais realista do desempenho dos modelos na previsão de irradiação solar.

#### 3.3 Análise das Lacunas de Dados

O conjunto de dados final continha 15.982 linhas, das quais 168 tinham dados faltantes, representando 1,05% do total. Considerando que esse percentual é inferior a 5%, assumiu-se que a presença dessas lacunas não afetaria significativamente a qualidade dos dados, uma vez que 98,95% das informações eram originais e representativas da série temporal. Para

preencher as lacunas, foi utilizada a técnica de interpolação, calculando-se a média dos valores de irradiação do dia anterior e do dia seguinte, no mesmo horário, para cada dado faltante.

Durante a investigação das causas das lacunas nos dados, descobriu-se que o problema estava relacionado ao desgaste da bateria da estação ao longo do tempo. Com a redução na capacidade de armazenamento da bateria, ela não conseguia manter o datalogger em funcionamento durante os períodos sem luz solar, fazendo com que o equipamento parasse de registrar dados durante esses horários e retomasse a operação apenas quando a luz solar estava presente, permitindo que o painel solar gerasse energia elétrica para alimentar o sistema.

#### 3.4 Implementação do Modelo LSTM

A partir da realização de experimentos preliminares, onde foram exploradas várias configurações de arquitetura, hiperparâmetros e métodos de otimização, selecionou-se 3 modelos que apresentaram os melhores desempenhos e serão descritos a seguir.

O Modelo 001 foi o que obteve o melhor desempenho nos experimentos preliminares. Ele consiste em uma arquitetura de rede neural recorrente com quatro camadas LSTM, regularização L1 e L2 nas duas primeiras camadas, *dropout* de 0,5 em todas as camadas LSTM, uma camada densa com 32 unidades e função de ativação ReLU, e uma camada de saída com uma unidade e função de ativação linear. O tamanho da janela de entrada utilizado neste modelo é de 168 horas, o que corresponde a uma semana de dados históricos.

O Modelo 002, ligeiramente diferente do anterior, teve como objetivo ampliar o tempo de aprendizado e o histórico de informações utilizado para a previsão (janela). Ele apresenta uma arquitetura idêntica ao Modelo 001, mas foi treinado por 1000 épocas e utiliza uma janela de entrada de 336 horas, o equivalente a 2 semanas de dados históricos.

Por fim, foram feitos pequenos ajustes nos hiperparâmetros do modelo anterior, cujo melhor resultado foi obtido através do Modelo 003. Ele possui uma arquitetura com três camadas LSTM, regularização L1 e L2 nas duas primeiras camadas, *dropout* de 0,1 em todas as camadas LSTM, uma camada densa com 64 unidades e função de ativação ReLU, e uma camada de saída com uma unidade e função de ativação linear. O tamanho da janela de entrada utilizado neste modelo também é de 336 horas, abrangendo 2 semanas de dados históricos.

Para o treinamento dos modelos LSTM, foi utilizado o otimizador RMSprop com uma taxa de aprendizado de 0,0001. O RMSprop é um otimizador adaptativo que ajusta a taxa de aprendizado para cada parâmetro, sendo eficiente em problemas de séries temporais. A função de perda escolhida foi o Erro Quadrático Médio (MSE, do inglês *Mean Square Error*), e as métricas utilizadas para avaliar o desempenho dos modelos foram o Erro Absoluto Médio (MAE, do inglês *Mean Absolut Error*) e o MSE. Os Modelos 001 e 003 foram treinados por 500 épocas, enquanto o Modelo 002 foi treinado por 1000 épocas. O tamanho do lote utilizado foi de 32 para os Modelos 001 e 002, e de 16 para o Modelo 003.

Durante o treinamento, foram também utilizados três *callbacks* para auxiliar no processo de otimização dos modelos. O primeiro *callback*, EarlyStopping, interrompe o treinamento se não houver melhoria na função de perda após um número especificado de épocas. Isso evita que o modelo continue a ser treinado desnecessariamente, caso não haja progresso significativo. O segundo *callback*, ReduceLROnPlateau, reduz a taxa de aprendizado quando a métrica monitorada para de melhorar. Essa abordagem permite que o modelo realize ajustes mais finos nos pesos, facilitando a convergência para um mínimo local ideal. Por fim, o *callback* ModelCheckpoint salva o melhor modelo durante o treinamento, com base na métrica monitorada. Isso garante que o modelo com o melhor desempenho seja preservado, mesmo que ocorram oscilações no desempenho ao longo das épocas de treinamento.

O tamanho da janela de entrada é um parâmetro importante na modelagem de séries temporais, pois determina a quantidade de dados históricos utilizados para fazer uma previsão. Para os Modelos 002 e 003, foi utilizado um tamanho de janela de 336, correspondendo a 2 semanas de dados horários. Já para o Modelo 001, foi utilizado um tamanho de janela de 168, correspondendo a 1 semana de dados horários. O ajuste adequado do tamanho da janela de entrada permite capturar características relevantes da série temporal, como sazonalidades diárias, picos e vales. A escolha do tamanho da janela de entrada foi baseada em experimentos e análises dos dados, buscando um equilíbrio entre a quantidade de informações históricas necessárias e a capacidade do modelo de generalizar para novas observações. Durante o treinamento dos modelos iniciais, percebeu-se que, ao aumentar o tamanho da janela, o modelo aprendia melhor as características dos dados, resultando na diminuição do *loss* e das outras métricas. No entanto, o aumento do tamanho da janela também impactava no tempo de processamento do modelo. Inicialmente, foram testadas janelas de 24 horas, mas o valor de 336 horas foi considerado o equilíbrio ideal entre a qualidade dos resultados e o desempenho computacional.

Neste trabalho, os três modelos LSTM com diferentes configurações de arquitetura e hiperparâmetros foram desenvolvidos utilizando a biblioteca Keras em Python, visando a previsão de irradiação solar de médio prazo. A escolha adequada do tamanho da janela de entrada, juntamente com os ajustes nos hiperparâmetros, permitiu obter modelos capazes de capturar as características relevantes dos dados e realizar previsões acuradas.

#### 3.5 Métricas de Avaliação do Modelo

Para avaliar o desempenho dos modelos LSTM desenvolvidos neste trabalho, foram utilizadas duas métricas amplamente empregadas em problemas de regressão: o Erro Quadrático Médio (MSE) e o Erro Absoluto Médio (MAE).

O MSE calcula a média dos erros quadráticos entre os valores previstos e os valores reais, penalizando erros maiores. Quanto menor o valor do MSE, melhor o desempenho do modelo. Já o MAE mede a média dos erros absolutos entre os valores previstos e os valores reais, fornecendo uma medida da magnitude média dos erros. Quanto menor o MAE, mais próximo de zero, melhor o modelo.

A utilização dessas duas métricas permite uma avaliação abrangente do desempenho dos modelos, considerando diferentes aspectos dos erros de previsão. Os modelos foram avaliados utilizando dados de irradiação solar de uma estação meteorológica em Redenção-CE, considerando apenas a irradiação solar como variável de entrada.

#### **4 RESULTADOS**

Neste estudo, foram desenvolvidos três modelos LSTM para a previsão de irradiação solar de médio prazo na região de Redenção-CE. Os modelos foram treinados e avaliados utilizando dados históricos de irradiação solar coletados por uma estação meteorológica local. As Tabelas 1, 2 e 3 apresentam os detalhes do desempenho de cada modelo, incluindo os hiperparâmetros utilizados, o tamanho da janela e as métricas de avaliação.

Tabela 1 – Hiperparâmetros e tamanho da janela dos modelos LSTM.

Exp.	Épocas	Batch	Janela
001	500	32	168
002	1000	32	336
003	500	16	336

Tabela 2 – Desempenho dos modelos LSTM no conjunto de treinamento.

			5	
Exp.	Loss	MAE	MSE	Melhor época
001	0,0092	0,0516	0,0090	294
002	0,0055	0,0383	0,0050	579
003	0,0049	0,0362	0,0045	474

Tabela 3 – Desempenho dos modelos LSTM no conjunto de teste.

Exp.	Loss	MAE	MSE
001	0,0078	0,0468	0,0076
002	0,0042	0,0327	0,0037
003	0,0039	0,0321	0,0036

O Modelo 001 possui uma arquitetura com quatro camadas LSTM, regularização L1 e L2 nas duas primeiras camadas, técnicas que ajudam a evitar o overfitting (sobreajuste) e melhorar a generalização do modelo. Também foi aplicado dropout, uma forma de regularização que desativa aleatoriamente alguns neurônios durante o treinamento, com uma taxa de 0,5 (ou 50%) em todas as camadas..O tamanho da janela de entrada utilizado para o Modelo 001 foi de 168 horas, o que corresponde a uma semana de dados. Após 500 épocas (ciclos completos) de treinamento, o modelo atingiu seu melhor desempenho na época 294. Nesse ponto, o modelo apresentou uma perda (loss) de 0,0092, um Erro Absoluto Médio (MAE) de 0,0516 e um Erro Quadrático Médio (MSE) de 0,0090 no conjunto de treinamento. No conjunto de teste, o modelo obteve uma perda de 0,0078, MAE de 0,0468 e MSE de 0,0076, indicando um bom desempenho

e capacidade de generalização. A Figura 13 apresenta o desempenho do Modelo 001 na previsão de irradiação solar.



Figura 13 – Desempenho do Modelo 001 na previsão de irradiação solar.

Fonte: Elaborado pelo autor.

O Modelo 002 possui a mesma arquitetura do Modelo 001, porém foi treinado por 1000 épocas e utilizou um tamanho de janela de entrada de 336 horas (2 semanas). O melhor desempenho foi alcançado na época 579, com uma perda de 0,0055, MAE de 0,0383 e MSE de 0,0050 no conjunto de treinamento. No conjunto de teste, o modelo obteve uma perda de 0,0042, MAE de 0,0327 e MSE de 0,0037. A Figura 14 ilustra o desempenho do Modelo 002 na previsão de irradiação solar.



Figura 14 – Desempenho do Modelo 002 na previsão de irradiação solar.

O Modelo 003 apresenta uma arquitetura com três camadas LSTM, regularização L1 e L2 nas duas primeiras camadas e dropout de 0,1 em todas as camadas. O tamanho da janela

Fonte: Elaborado pelo autor.

de entrada utilizado foi de 336 horas (2 semanas). Após 500 épocas de treinamento, o modelo atingiu seu melhor desempenho na época 474, com uma perda de 0,0049, MAE de 0,0362 e MSE de 0,0045 no conjunto de treinamento. No conjunto de teste, o modelo obteve uma perda de 0,0039, MAE de 0,0321 e MSE de 0,0036. A Figura 15 mostra o desempenho do Modelo 003 na previsão de irradiação solar.



Figura 15 – Desempenho do Modelo 003 na previsão de irradiação solar.

Ao analisar os gráficos de previsão de irradiação solar dos três modelos, é possível observar que todos eles foram capazes de capturar de forma satisfatória a sazonalidade diária e os padrões de picos e vales presentes nos dados reais. Os modelos demonstraram uma boa capacidade de generalização, produzindo previsões próximas aos valores reais, mesmo para o conjunto de teste, que não foi utilizado durante o treinamento.

Dentre os três modelos desenvolvidos, o Modelo 003 obteve o melhor desempenho geral, apresentando os menores valores de Loss, MAE e MSE tanto no conjunto de treinamento quanto no conjunto de teste. Esse resultado sugere que a arquitetura do Modelo 003, com três camadas LSTM, regularização L1 e L2 e dropout de 0,1, juntamente com o tamanho de janela de entrada de 336 horas, é a mais adequada para a previsão de irradiação solar de médio prazo na região de Redenção-CE.

É importante ressaltar que, apesar dos bons resultados obtidos, os modelos foram desenvolvidos considerando apenas a irradiação solar como variável de entrada. A inclusão de outras variáveis meteorológicas, como temperatura, umidade e velocidade do vento, poderia potencialmente melhorar ainda mais o desempenho dos modelos e fornecer *insights* adicionais sobre a dinâmica da irradiação solar na região de Redenção-CE.

Fonte: Elaborado pelo autor.

Além disso, os modelos foram avaliados utilizando dados da estação meteorológica em um ponto geográfico, o que limita a generalização dos resultados para outras regiões com características climáticas diferentes. Para uma avaliação mais abrangente, seria interessante testar os modelos em dados de outras localidades na região de Redenção-CE e comparar seu desempenho em diferentes condições climáticas.

Apesar dessas limitações, os resultados obtidos neste estudo demonstram o potencial das redes neurais LSTM para a previsão de irradiação solar de curto prazo. Os modelos desenvolvidos podem ser aplicados para otimizar o planejamento e a operação de sistemas fotovoltaicos na região de Redenção-CE, auxiliando na tomada de decisões relacionadas à geração de energia solar e contribuindo para a integração eficiente dessa fonte renovável na matriz energética local.

#### **5 CONCLUSÕES E TRABALHOS FUTUROS**

Neste estudo, foram desenvolvidos e avaliados três modelos de redes neurais recorrentes LSTM para a previsão de irradiação solar de médio prazo na região de Redenção-CE. Os modelos foram treinados utilizando dados históricos de irradiação solar coletados por uma estação meteorológica local durante o período de dezembro de 2020 a setembro de 2022.

Os resultados obtidos demonstraram que os modelos LSTM são capazes de capturar padrões temporais complexos nos dados de irradiação solar e produzir previsões precisas. O Modelo 003, com sua arquitetura específica de três camadas LSTM, regularização L1 e L2, dropout de 0,1 e tamanho de janela de entrada de 336 horas (4 semanas), apresentou o melhor desempenho geral, com os menores valores de perda (0,0039), MAE (0,0321) e MSE (0,0036) no conjunto de teste.

A análise dos gráficos de previsão revelou que todos os modelos foram capazes de reproduzir de forma satisfatória a sazonalidade diária e os padrões de picos e vales presentes nos dados reais. Isso indica que as redes LSTM são adequadas para modelar as dependências temporais de longo prazo na série de irradiação solar e generalizar bem para dados não vistos durante o treinamento.

Os resultados promissores obtidos neste estudo abrem caminho para a aplicação de modelos LSTM na otimização de sistemas fotovoltaicos na região de Redenção-CE. Previsões precisas de irradiação solar de médio prazo podem auxiliar no planejamento e operação eficientes desses sistemas, permitindo uma melhor gestão da geração de energia solar e sua integração à rede elétrica.

No entanto, é importante ressaltar algumas limitações deste estudo. Primeiramente, os modelos foram desenvolvidos considerando apenas a irradiação solar como variável de entrada. A inclusão de outras variáveis meteorológicas, como temperatura, umidade e velocidade do vento, poderia potencialmente melhorar o desempenho dos modelos e fornecer insights adicionais sobre a dinâmica da irradiação solar na região.

Além disso, os modelos foram avaliados utilizando dados de uma única estação meteorológica, o que limita a generalização dos resultados para outras regiões com características climáticas diferentes. Para uma avaliação mais abrangente, seria interessante testar os modelos em dados de outras localidades e comparar seu desempenho em diferentes condições climáticas.

Outro aspecto a ser considerado é a importância da qualidade dos dados utilizados. Neste estudo, foi necessário lidar com a presença de lacunas nos dados, preenchendo-as por meio de interpolação. Embora o percentual de dados faltantes tenha sido relativamente baixo (1,05%), é fundamental garantir a integridade e consistência dos dados para obter previsões confiáveis.

Como trabalhos futuros, sugere-se a exploração de modelos LSTM com arquiteturas mais complexas, como redes bidirecionais e mecanismos de atenção, que podem capturar dependências temporais ainda mais sofisticadas. Além disso, a incorporação de variáveis meteorológicas adicionais e a aplicação de técnicas de seleção de características podem aprimorar a capacidade preditiva dos modelos.

### REFERÊNCIAS

ABSOLAR. Infográfico ABSOLAR: Energia Solar Fotovoltaica no Brasil. 2024. <a href="https://www.absolar.org.br/mercado/infografico/">https://www.absolar.org.br/mercado/infografico/</a>. Acesso em: 16 mar. 2024.

ALEXANDER, D. L. J.; TROPSHA, A.; WINKLER, D. A. Beware of r2: Simple, unambiguous assessment of the prediction accuracy of qsar and qspr models. **Journal of Chemical Information and Modeling**, v. 55, n. 7, p. 1316–1322, 2015. PMID: 26099013. Disponível em: <a href="https://doi.org/10.1021/acs.jcim.5b00206">https://doi.org/10.1021/acs.jcim.5b00206</a>>.

ALZAHRANI, A.; SHAMSI, P.; DAGLI, C. H.; FERDOWSI, M. Solar irradiance forecasting using deep neural networks. **Procedia Computer Science**, v. 114, p. 304–313, 2017. Disponível em: <a href="https://api.semanticscholar.org/CorpusID:196135553">https://api.semanticscholar.org/CorpusID:196135553</a>>.

ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA. **Evolução da Fonte Solar Fotovoltaica no Brasil**. 2024. Disponível em: <a href="https://www.absolar.org.br/mercado/">https://www.absolar.org.br/mercado/</a> infografico/>. Acesso em: 16 mar. 2024.

BENGIO, Y. Practical recommendations for gradient-based training of deep architectures. In: \_\_\_\_\_. Neural Networks: Tricks of the Trade: Second Edition. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 437–478. ISBN 978-3-642-35289-8. Disponível em: <https://doi.org/10.1007/978-3-642-35289-8\_26>.

BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. **IEEE Transactions on Neural Networks**, v. 5, n. 2, p. 157–166, 1994.

BERGSTRA, J.; BARDENET, R.; BENGIO, Y.; KéGL, B. Algorithms for hyper-parameter optimization. In: SHAWE-TAYLOR, J.; ZEMEL, R.; BARTLETT, P.; PEREIRA, F.; WEINBERGER, K. (Ed.). Advances in Neural Information Processing Systems. Curran Associates, Inc., 2011. v. 24. Disponível em: <a href="https://proceedings.neurips.cc/paper\_files/paper/2011/file/86e8f7ab32cfd12577bc2619bc635690-Paper.pdf">https://proceedings.neurips.cc/paper\_files/paper/2011/file/86e8f7ab32cfd12577bc2619bc635690-Paper.pdf</a>>.

BOTTOU, L. Large-scale machine learning with stochastic gradient descent. In: LECHEVALLIER, Y.; SAPORTA, G. (Ed.). **Proceedings of COMPSTAT'2010**. Heidelberg: Physica-Verlag HD, 2010. p. 177–186. ISBN 978-3-7908-2604-3.

BRAHMA, B.; WADHVANI, R. Solar irradiance forecasting based on deep learning methodologies and multi-site data. **Symmetry**, v. 12, p. 1830, 2020. Disponível em: <a href="https://api.semanticscholar.org/CorpusID:227276579">https://api.semanticscholar.org/CorpusID:227276579</a>.

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**, v. 7, n. 3, p. 1247–1250, 2014. Disponível em: <a href="https://gmd.copernicus.org/articles/7/1247/2014/">https://gmd.copernicus.org/articles/7/1247/2014/</a>>.

CHANDEL, S.; Nagaraju Naik, M.; CHANDEL, R. Review of solar photovoltaic water pumping system technology for irrigation and community drinking water supplies. **Renewable and Sustainable Energy Reviews**, v. 49, p. 1084–1099, 2015. ISSN 1364-0321. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S1364032115003536">https://www.sciencedirect.com/science/article/pii/S1364032115003536</a>>.

CHO, K.; MERRIËNBOER, B. van; GULCEHRE, C.; BAHDANAU, D.; BOUGARES, F.; SCHWENK, H.; BENGIO, Y. Learning phrase representations using RNN encoder–decoder for statistical machine translation. In: MOSCHITTI, A.; PANG, B.; DAELEMANS, W. (Ed.).

**Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing** (EMNLP). Doha, Qatar: Association for Computational Linguistics, 2014. p. 1724–1734. Disponível em: <a href="https://aclanthology.org/D14-1179">https://aclanthology.org/D14-1179</a>>.

CHUNG, J.; GÜLÇEHRE, Ç.; CHO, K.; BENGIO, Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. **CoRR**, abs/1412.3555, 2014. Disponível em: <a href="http://arxiv.org/abs/1412.3555">http://arxiv.org/abs/1412.3555</a>.

CRESWELL, J. W. **Projeto de pesquisa: métodos qualitativo, quantitativo e misto**. [S.1.]: Artmed, 2010. ISBN 9788536316063.

DANCKER, J. A Brief Introduction to Recurrent Neural Networks: An introduction to rnn, lstm, and gru and their implementation. 2022. Disponível em: <a href="https://towardsdatascience.com/">https://towardsdatascience.com/</a> a-brief-introduction-to-recurrent-neural-networks-638f64a61ff4>. Acesso em: 25 mar. 2024.

DIAGNE, M.; DAVID, M.; LAURET, P.; BOLAND, J.; SCHMUTZ, N. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, v. 27, p. 65–76, 2013. ISSN 1364-0321. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S1364032113004334">https://www.sciencedirect.com/science/article/pii/S1364032113004334</a>>.

DUFFIE, J. A.; BECKMAN, W. A. **Solar Engineering of Thermal Processes**. 4. ed. Hoboken: John Wiley & Sons, 2013.

GIL, A. C. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2002.

Global Solar Atlas. **Map and data downloads**. 2019. Disponível em: <a href="https://globalsolaratlas.info/download/brazil">https://globalsolaratlas.info/download/brazil</a>). Acesso em: 16 mar. 2024.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: TEH, Y. W.; TITTERINGTON, M. (Ed.). **Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics**. Chia Laguna Resort, Sardinia, Italy: PMLR, 2010. (Proceedings of Machine Learning Research, v. 9), p. 249–256. Disponível em: <a href="https://proceedings.mlr.press/v9/glorot10a.html">https://proceedings.mlr.press/v9/glorot10a.html</a>.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: PMLR. **Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics**. Fort Lauderdale, FL, USA, 2011. p. 315–323.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.1.]: MIT Press, 2016. <a href="http://www.deeplearningbook.org">http://www.deeplearningbook.org</a>>.

GRUPO QUANTA. Energia Solar: 4 fatores que impactam na geração. 2021. Disponível em: <a href="https://grupoquanta.com.br/energia-solar-4-fatores-que-impactam-na-geracao/">https://grupoquanta.com.br/energia-solar-4-fatores-que-impactam-na-geracao/</a>. Acesso em: 16 mar. 2024.

HAYKIN, S. Neural Networks and Learning Machines. [S.l.]: Pearson, 2009. (Signals and Communication Technology). ISBN 0131471392.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: **2015 IEEE International Conference on Computer Vision (ICCV)**. [S.l.: s.n.], 2015. p. 1026–1034.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 11 1997. ISSN 0899-7667. Disponível em: <a href="https://doi.org/10.1162/neco.1997.9.8.1735">https://doi.org/10.1162/neco.1997.9.8.1735</a>-

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679–688, 2006. ISSN 0169-2070. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0169207006000239">https://www.sciencedirect.com/science/article/pii/S0169207006000239</a>>.

INMAN, R. H.; PEDRO, H. T.; COIMBRA, C. F. Solar forecasting methods for renewable energy integration. **Progress in Energy and Combustion Science**, v. 39, n. 6, p. 535–576, 2013. ISSN 0360-1285. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0360128513000294">https://www.sciencedirect.com/science/article/pii/S0360128513000294</a>>.

IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: BACH, F.; BLEI, D. (Ed.). **Proceedings of the 32nd International Conference on Machine Learning**. Lille, France: PMLR, 2015. (Proceedings of Machine Learning Research, v. 37), p. 448–456. Disponível em: <a href="https://proceedings.mlr.press/v37/ioffe15.html">https://proceedings.mlr.press/v37/ioffe15.html</a>>.

ISLAM, M.; MEKHILEF, S.; SAIDUR, R. Progress and recent trends of wind energy technology. **Renewable and Sustainable Energy Reviews**, v. 21, p. 456–468, 2013. ISSN 1364-0321. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S1364032113000312">https://www.sciencedirect.com/science/article/pii/S1364032113000312</a>>.

JANOCHA, K.; CZARNECKI, W. M. On loss functions for deep neural networks in classification. **CoRR**, abs/1702.05659, 2017. Disponível em: <a href="http://arxiv.org/abs/1702.05659">http://arxiv.org/abs/1702.05659</a>>.

JAYALAKSHMI, T.; SANTHAKUMARAN, A. Statistical normalization and back propagation for classification. **International Journal of Computer Theory and Engineering**, v. 3, n. 1, p. 1793–8201, 2011.

KIM, S.; KIM, H. A new metric of absolute percentage error for intermittent demand forecasts. **International Journal of Forecasting**, v. 32, n. 3, p. 669–679, 2016. ISSN 0169-2070. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0169207016000121">https://www.sciencedirect.com/science/article/pii/S0169207016000121</a>.

KINGMA, D. P.; BA, J. Adam: A Method for Stochastic Optimization. 2017.

KUKAčKA, J.; GOLKOV, V.; CREMERS, D. Regularization for Deep Learning: A Taxonomy. 2017.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. Disponível em: <a href="https://www.nature.com/articles/nature14539">https://www.nature.com/articles/nature14539</a>>. Acesso em: 20 mar. 2024.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998.

LECUN, Y. A.; BOTTOU, L.; ORR, G. B.; MÜLLER, K.-R. Efficient backprop. In: \_\_\_\_\_. Neural Networks: Tricks of the Trade: Second Edition. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 9–48. ISBN 978-3-642-35289-8. Disponível em: <https://doi.org/10.1007/978-3-642-35289-8\_3>.

MARCONI, M. A.; LAKATOS, E. M. Fundamentos de metodologia científica. 5. ed. São Paulo: Atlas, 2003.

MEKHILEF, S.; SAIDUR, R.; SAFARI, A. A review on solar energy use in industries. **Renewable and Sustainable Energy Reviews**, v. 15, n. 4, p. 1777–1790, 2011. ISSN 1364-0321. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S1364032110004533">https://www.sciencedirect.com/science/article/pii/S1364032110004533</a>>.

MIKOLOV, T.; KARAFIáT, M.; BURGET, L.; ČERNOCKý, J.; KHUDANPUR, S. Recurrent neural network based language model. In: **Proc. Interspeech 2010**. [S.l.: s.n.], 2010. p. 1045–1048.

NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: ICML. **Proceedings of the 27th International Conference on Machine Learning**. Haifa, Israel, 2010.

NG, A. Y. Feature selection, 11 vs. 12 regularization, and rotational invariance. In: **Proceedings of the Twenty-First International Conference on Machine Learning**. New York, NY, USA: Association for Computing Machinery, 2004. (ICML '04), p. 78. ISBN 1581138385. Disponível em: <a href="https://doi.org/10.1145/1015330.1015435">https://doi.org/10.1145/1015330.1015435</a>>.

PALMIERE, S. E. Arquiteturas e Topologias de Redes Neurais Artificiais: Feedforward de camadas múltiplas. 2016. Disponível em: <a href="https://embarcados.com.br/redes-neurais-artificiais/">https://embarcados.com.br/redes-neurais-artificiais/</a>. Acesso em: 24 mar. 2024.

PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. L.; RÜTHER, R.; ABREU, S. L.; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. Atlas brasileiro de energia solar. 2. ed. São José dos Campos: INPE, 2017. 80 p.

PEREZ, L.; WANG, J. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. 2017.

PINHO, J. T.; GALDINO, M. A. (Ed.). Manual de Engenharia para Sistemas Fotovoltaicos. Rio de Janeiro: CEPEL-CRESESB, 2014.

PRECHELT, L. Early stopping - but when? In: \_\_\_\_\_. **Neural Networks: Tricks of the Trade**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998. p. 55–69. ISBN 978-3-540-49430-0. Disponível em: <a href="https://doi.org/10.1007/3-540-49430-8\_3">https://doi.org/10.1007/3-540-49430-8\_3</a>.

PRODANOV, C. C.; FREITAS, E. C. Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. [S.l.]: Feevale, 2013. ISBN 9788575228133.

QIAN, N. On the momentum term in gradient descent learning algorithms. **Neural Networks**, v. 12, n. 1, p. 145–151, 1999. ISSN 0893-6080. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0893608098001166">https://www.sciencedirect.com/science/article/pii/S0893608098001166</a>>.

QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by lstm. **Energy**, v. 148, p. 461–468, 2018. ISSN 0360-5442. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0360544218302056">https://www.sciencedirect.com/science/article/pii/S0360544218302056</a>>.

REN21. **Renewables 2023 Global Status Report**. Paris: REN21 Secretariat, 2023. Disponível em: <a href="https://www.ren21.net/reports/global-status-report/">https://www.ren21.net/reports/global-status-report/</a>.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.

RUDER, S. An overview of gradient descent optimization algorithms. 2017.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, 1986.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. **Neural Networks**, v. 61, p. 85–117, 2015. ISSN 0893-6080. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0893608014002135">https://www.sciencedirect.com/science/article/pii/S0893608014002135</a>.

SIMARD, P.; STEINKRAUS, D.; PLATT, J. Best practices for convolutional neural networks applied to visual document analysis. In: **Seventh International Conference on Document Analysis and Recognition, 2003. Proceedings.** [S.l.: s.n.], 2003. p. 958–963.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, n. 56, p. 1929–1958, 2014. Disponível em: <a href="http://jmlr.org/papers/v15/srivastava14a.html">http://jmlr.org/papers/v15/srivastava14a.html</a>.

SUTSKEVER, I.; MARTENS, J.; DAHL, G.; HINTON, G. On the importance of initialization and momentum in deep learning. In: DASGUPTA, S.; MCALLESTER, D. (Ed.). **Proceedings of the 30th International Conference on Machine Learning**. Atlanta, Georgia, USA: PMLR, 2013. (Proceedings of Machine Learning Research, 3), p. 1139–1147. Disponível em: <a href="https://proceedings.mlr.press/v28/sutskever13.html">https://proceedings.mlr.press/v28/sutskever13.html</a>.

SUTSKEVER, I.; VINYALS, O.; LE, Q. V. Sequence to sequence learning with neural networks. In: GHAHRAMANI, Z.; WELLING, M.; CORTES, C.; LAWRENCE, N.; WEINBERGER, K. (Ed.). Advances in Neural Information Processing Systems. Curran Associates, Inc., 2014. v. 27. Disponível em: <a href="https://proceedings.neurips.cc/paper\_files/paper/2014/file/a14ac55a4f27472c5d894ec1c3c743d2-Paper.pdf">https://proceedings.neurips.cc/paper\_files/paper/2014/file/a14ac55a4f27472c5d894ec1c3c743d2-Paper.pdf</a>.

TIELEMAN, T.; HINTON, G. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. 2012. COURSERA: Neural Networks for Machine Learning.

URZAGASTI, C.; MACIEL, J.; WENTZ, V.; LEDESMA, J.; JUNIOR, O. A. Comparação da acurácia de modelos de redes neurais artificiais na predição da irradiância solar e geração de energia fotovoltaica. In: Anais do XVIII Congresso Latino-Americano de Software Livre e Tecnologias Abertas. Porto Alegre, RS, Brasil: SBC, 2021. p. 53–58. ISSN 0000-0000. Disponível em: <a href="https://sol.sbc.org.br/index.php/latinoware/article/view/19905">https://sol.sbc.org.br/index.php/latinoware/article/view/19905</a>>.

VIANA, T.; RüTHER, R.; MARTINS, F.; PEREIRA, E. Assessing the potential of concentrating solar photovoltaic generation in brazil with satellite-derived direct normal irradiation. **Solar Energy**, v. 85, n. 3, p. 486–495, 2011. ISSN 0038-092X. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0038092X10003944">https://www.sciencedirect.com/science/article/pii/S0038092X10003944</a>>.

VILLALVA, M. G. Energia Solar Fotovoltaica: Conceitos e Aplicações. 2. ed. São Paulo: Érica, 2015.

VINICIUS, A. **Redes Neurais Artificiais**: Perceptron. 2017. Disponível em: <a href="https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39">https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39</a>>. Acesso em: 24 mar. 2024.

VOYANT, C.; NOTTON, G.; KALOGIROU, S.; NIVET, M.-L.; PAOLI, C.; MOTTE, F.; FOUILLOY, A. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, v. 105, p. 569–582, 2017. ISSN 0960-1481. Disponível em: <a href="https://www.sciencedirect.com/science/article/pii/S0960148116311648">https://www.sciencedirect.com/science/article/pii/S0960148116311648</a>>.

VOYANT, C.; NOTTON, G.; KALOGIROU, S.; NIVET, M.-L.; PAOLI, C.; MOTTE, F.; FOUILLOY, A. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, v. 105, p. 569–582, 2017.

WANG, Y.; HUANG, M.; ZHU, X.; ZHAO, L. Attention-based LSTM for aspect-level sentiment classification. In: SU, J.; DUH, K.; CARRERAS, X. (Ed.). **Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing**. Austin, Texas: Association for Computational Linguistics, 2016. p. 606–615. Disponível em: <a href="https://aclanthology.org/D16-1058">https://aclanthology.org/D16-1058</a>>.

YANG, D.; ALESSANDRINI, S.; ANTONANZAS, J.; ANTONANZAS-TORRES, F.; BADESCU, V.; BEYER, H. G.; BLAGA, R.; BOLAND, J.; BRIGHT, J. M.; COIMBRA, C. F.; DAVID, M.; FRIMANE Âzeddine; GUEYMARD, C. A.; HONG, T.; KAY, M. J.; KILLINGER, S.; KLEISSL, J.; LAURET, P.; LORENZ, E.; van der Meer, D.; PAULESCU, M.; PEREZ, R.; PERPIñáN-LAMIGUEIRO, O.; PETERS, I. M.; REIKARD, G.; RENNÉ, D.; SAINT-DRENAN, Y.-M.; SHUAI, Y.; URRACA, R.; VERBOIS, H.; VIGNOLA, F.; VOYANT, C.; ZHANG, J. Verification of deterministic solar forecasts. **Solar Energy**, v. 210, p. 20–37, 2020. ISSN 0038-092X. Special Issue on Grid Integration. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0038092X20303947>.