

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
GOIÁS
CÂMPUS ITUMBIARA
CURSO DE BACHARELADO EM ENGENHARIA ELÉTRICA**

JESIEL PEREIRA VIEIRA

**REDES NEURAIS RECORRENTES PARA PREVISÃO DE RADIAÇÃO
SOLAR GLOBAL**

**ITUMBIARA-GO
2022**

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO
NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG**

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| <input type="checkbox"/> Tese | <input type="checkbox"/> Artigo Científico |
| <input type="checkbox"/> Dissertação | <input type="checkbox"/> Capítulo de Livro |
| <input type="checkbox"/> Monografia – Especialização | <input type="checkbox"/> Livro |
| <input checked="" type="checkbox"/> TCC - Graduação | <input type="checkbox"/> Trabalho Apresentado em Evento |
| <input type="checkbox"/> Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Jesiel Pereira Vieira

Matrícula: 20152040070180

Título do Trabalho: Redes neurais recorrentes para previsão de radiação solar global

Autorização - Marque uma das opções

1. Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ___/___/___ (Embargo);
3. Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

- O documento está sujeito a registro de patente.
 O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
 Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- ii. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Itumbiara-GO, 05/09/2022.

Local Data



Assinatura do Autor e/ou Detentor dos Direitos Autorais

JESIEL PEREIRA VIEIRA

**REDES NEURAS RECORRENTES PARA PREVISÃO DE RADIAÇÃO
SOLAR GLOBAL**

Trabalho de Conclusão de Curso apresentado à Banca examinadora do Curso de Bacharelado em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Câmpus Itumbiara, como parte dos requisitos necessários para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Marcelo Escobar de Oliveira.

**ITUMBIARA-GO
2022**

Dados Internacionais de Catalogação na Publicação (CIP)

V658r Vieira, Jesiel Pereira

Redes neurais recorrentes para previsão de radiação solar global./ Jesiel Pereira Vieira. -- Itumbiara, 2023.

90 p. : il. color.

Trabalho de conclusão de curso (Bacharelado em Engenharia Elétrica) - Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Câmpus Itumbiara, 2023.

Orientador: Prof. Dr. Marcelo Escobar de Oliveira.

1. Energia solar. 2. Geração de energia fotovoltaica. 3. Redes elétricas inteligentes. I. Título. II. Oliveira, Marcelo Escobar de . III. Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

CDD 621.47

Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Biblioteca Maria Gabriela Pacheco Pardey / Câmpus Itumbiara
Bibliotecário: Eduardo Pereira Resende CRB1/3266



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS ITUMBIARA

Termo de Aprovação

Jesiel Pereira Vieira

REDES NEURAIS RECORRENTES PARA PREVISÃO DE RADIAÇÃO SOLAR GLOBAL

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Goiás – Câmpus Itumbiara, como parte dos requisitos para a obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho de Conclusão de Curso defendido e aprovado, em 5 de setembro de 2022, pela banca examinadora constituída pelos seguintes membros:

BANCA EXAMINADORA

Prof. Dr. Marcelo Escobar de Oliveira - Orientador

Instituto Federal de Goiás, Câmpus Itumbiara

Prof. Dr. Ghunter Paulo Viajante - Membro interno

Instituto Federal de Goiás, Câmpus Itumbiara

Dr. Leonardo Garcia Marques - Membro interno

Instituto Federal de Goiás, Câmpus Itumbiara

Itumbiara – GO

2022

Documento assinado eletronicamente por:

- **Ghunter Paulo Viajante**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 03/07/2023 17:02:50.
- **Leonardo Garcia Marques**, ANALISTA DE TEC DA INFORMACAO, em 03/07/2023 17:00:02.
- **Marcelo Escobar de Oliveira**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 03/07/2023 16:56:55.

Este documento foi emitido pelo SUAP em 03/07/2023. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 426732

Código de Autenticação: 661d8639cb



Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Avenida Furnas, nº 55, Bairro Village Imperial, ITUMBIARA / GO, CEP 75524-010
(64) 2103-5622 (ramal: 5622)

Dedico este trabalho aos meus pais, pois graças ao apoio incondicional deles que hoje posso concluir essa etapa na minha vida. Expresso também minha gratidão a todos os professores do curso de Engenharia Elétrica que me forneceram as bases para a realização deste trabalho.

AGRADECIMENTOS

Ao final dessa longa jornada, é impossível não olhar para trás e considerar as diversas formas de apoio que foram necessárias para conseguir alcançar o momento atual. Agradeço primeiramente aos meus pais Maria Aparecida e Lazaro Martins pelo apoio incondicional que tornou possível minha graduação.

Gostaria de agradecer a todos os professores da instituição que contribuíram significativamente com seu conhecimento, tornando minha formação acadêmica possível. Em especial agradeço ao meu orientador Dr. Marcelo Escobar de Oliveira pelo suporte e parceria durante todo meu período na instituição até esse momento.

Estendo meus agradecimentos a todos os funcionários do Instituto Federal de Goiás – Câmpus Itumbiara, que contribuíram direta ou indiretamente no meu desenvolvimento ao longo desses anos.

Agradeço também a todos os amigos que estiveram juntos nessa trajetória, compartilhando experiências e momentos que tornaram todo o processo mais leve.

A todos vocês, meu muito obrigado.

*Que os nossos esforços desafiem as
impossibilidades. Lembrai-vos de que as
grandes proezas da história foram
conquistadas do que parecia impossível*

CHARLES CHAPLIN

RESUMO

No cenário mundial, as redes inteligentes estão se difundindo e mostrando uma tendência em busca da otimização de sistemas elétricos de potência, em especial os sistemas de distribuição. Este contexto é consequência de diversos fatores como a diversificação da matriz elétrica com adição de fontes renováveis, aumento da demanda de energia elétrica e geração descentralizada. As abordagens recentes, aplicando técnicas de inteligência artificial, se destacam na literatura utilizando modelos de regressão que buscam prever variáveis relacionadas à geração de energia. Assim, neste trabalho explora-se a aplicação de redes neurais artificiais na previsão de radiação solar global a curto prazo, como auxílio na tomada de decisões para controle e otimização em sistemas de geração solar fotovoltaicos. Com essa finalidade, foram desenvolvidas três arquiteturas de redes neurais com dois conjuntos de dados distintos, comparando o desempenho dos modelos no aspecto de acurácia e tempo de execução. Para o desenvolvimento da proposta, inicialmente realizou-se um estudo abordando a matriz energética brasileira, as fontes renováveis de energia (destacando a geração solar fotovoltaica) e trabalhos que aplicaram o conceito de redes neurais para a previsão de variáveis relacionadas a geração de energia. Ao término da revisão bibliográfica, a rede neural recorrente foi proposta para realizar as previsões de radiação solar global. Por conseguinte, foi apresentada a comparação entre as principais células recorrentes (LSTM e GRU), bem como sua aplicação conjunta em uma configuração híbrida. Assim, os resultados de ambos os modelos foram apontados de modo a definir a configuração mais adequada, a partir da qual foram realizadas as análises estatísticas e gráficas que embasaram as conclusões do presente trabalho.

Palavras-chave: Energia Solar. Redes Neurais Artificiais. Radiação Global. Previsão. Redes Neurais Recorrentes.

ABSTRACT

Worldwide smart grids are spreading and showing a trend towards the optimization of electrical power systems, especially the distribution systems. This is a consequence of several factors such as the diversification of the electricity mix with the addition of renewable sources, increased demand for electricity and decentralized generation. Recent approaches, applying artificial intelligence techniques, emerge in the literature using regression models that seek to predict variables related to energy generation. Thus, this work explores the application of artificial neural networks in the prediction of global radiation in the short term, as an aid in decision making for control and optimization in photovoltaic generation systems. Therefore, three neural network architectures were developed with two distinct datasets, comparing the performance of the models in terms of accuracy and execution time. For the development of the proposal, initially a study was accomplished addressing the Brazil electricity mix, renewable energy sources (especially photovoltaic generation) and articles that applied the concept of neural networks for the prediction of energy generation related variables. At the end of the literature review, a recurrent neural network was developed to perform solar global radiation predictions. Therefore, the comparison between the main recurrent cells (LSTM and GRU) was presented, as well as their joint application in a hybrid configuration. Thus, the results of both models were used in order to define the most appropriate configuration, based on the application of statistical and graphical analyses, which supported the conclusions of the present work.

Keywords: *Solar Energy. Artificial Neural Networks. Global Radiation. Forecasting. Recurrent Neural Networks.*

LISTA DE ILUSTRAÇÕES

Figura 1 – Insolação anual média brasileira.....	21
Figura 2 – Matriz elétrica brasileira em janeiro de 2022.....	23
Figura 3 – Preços das diferentes fontes de energia renováveis.....	24
Figura 4 – Marco histórico da energia solar em território nacional entre os anos de 2011 e 2018	25
Figura 5 – Sistema fotovoltaico <i>on-grid</i>	26
Figura 6 – Sistema fotovoltaico <i>off-grid</i>	27
Figura 7 – Neurônio biológico.....	28
Figura 8 – Esquema de uma rede neural artificial	29
Figura 9 – Modelo de RNA criado por McCulloch e Pitts	32
Figura 10 – Modelo rede neural recorrente	39
Figura 11 – Modelo célula LSTM.....	43
Figura 12 – Modelo célula GRU	44
Figura 13 – Função Sigmoides	52
Figura 14 – Função Tangente Hiperbólica	53
Figura 15 – Função ReLU	54
Figura 16 – Técnica da janela de um período	55
Figura 17 – Técnica da janela de n períodos	55
Figura 18 – Fluxograma da rede	63
Figura 19 – Correlação dos dados	64
Figura 20 – Dados meteorológicos em janeiro de 2019.....	65
Figura 21 – Média diária de energia solar de ondas curtas em Itumbiara e Indaial ..	66
Figura 22– Entradas e saídas do conjunto C1	67
Figura 23– Entradas e saídas do conjunto C2	68
Figura 24 – Rede neural GRU.....	68
Figura 25 – Rede neural LSTM	69
Figura 26 – Rede neural híbrida LSTM+GRU	69
Figura 27 – Dados de entrada da rede.....	73
Figura 28 – Perdas durante o treinamento e validação do modelo	74
Figura 29 – Gráfico de dispersão	75
Figura 30 – Comparação entre medição e previsão de radiação global	75
Figura 31 – Previsão da radiação global ao longo de 24 horas.....	76

Figura 32 – Previsões em janeiro na cidade de Itumbiara	77
Figura 33 – Previsões em abril na cidade de Itumbiara	77
Figura 34 – Previsões em julho na cidade de Itumbiara.....	78
Figura 35 – Previsões em janeiro na cidade de Indaial.....	79
Figura 36 – Previsões em abril na cidade de Indaial.....	79
Figura 37 – Previsões em julho na cidade de Indaial	80

LISTA DE TABELAS

Tabela 1 – Resultados para o conjunto C1	71
Tabela 2 – Resultados para o conjunto C2.....	72
Tabela 3 – Métricas de Acurácia.....	73
Tabela 4 – Resultados para a cidade de Itumbiara.....	78
Tabela 5 – Resultados para a cidade de Indaial	80

SUMÁRIO

1	INTRODUÇÃO	13
1.1	ESTRUTURAÇÃO DO TRABALHO	15
2	MATRIZ ENERGÉTICA E GERAÇÃO SOLAR DE ENERGIA	16
2.1	MATRIZ ENERGÉTICA BRASILEIRA E AS FONTES RENOVÁVEIS DE ENERGIA	16
2.2	RADIAÇÃO SOLAR E GERAÇÃO DE ENERGIA	18
2.2.1	<i>Energia Solar</i>	19
2.2.2	<i>Geração solar de energia elétrica</i>	20
2.2.3	<i>Modos de geração de energia solar fotovoltaica</i>	25
3	REDES NEURAS ARTIFICIAIS	28
3.1	REDES NEURAS ARTIFICIAIS (RNA)	28
3.2	REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DA GERAÇÃO DE ENERGIA FOTOVOLTAICA	34
4	REDES NEURAS RECORRENTES	39
4.1	REDE NEURAL RECORRENTE	39
4.2	CONCEITOS	40
4.2.1	<i>Treinamento e Teste</i>	41
4.2.2	<i>Época</i>	41
4.2.2.1	Tamanho do lote	42
4.2.3	<i>Células</i>	42
4.2.3.1	Célula Long Short-Term Memory (LSTM)	42
4.2.3.2	Célula Gated Recurrent Unit (GRU)	44
4.2.4	<i>Normalização dos dados</i>	45
4.2.5	<i>Algoritmo otimizador</i>	45
4.2.5.1	Algoritmo RMSprop	46
4.2.5.2	Algoritmo Adam	46
4.2.6	<i>Taxa de aprendizagem</i>	47
4.2.7	<i>Avaliação</i>	48
4.2.7.1	MSE	48
4.2.7.2	RMSE	49
4.2.7.3	MAE	49
4.2.7.4	MAPE	49
4.2.7.5	R ²	50
4.2.8	<i>Função de Ativação</i>	51
4.2.8.1	Função Sigmoide	51
4.2.8.2	Função Tangente Hiperbólica	52
4.2.8.3	Função ReLU	53

4.2.9	<i>Técnica de Janela</i>	54
4.2.10	<i>Critério de parada</i>	56
5	LINGUAGEM DE PROGRAMAÇÃO PYTHON	57
5.1	NUMPY.....	57
5.2	PANDAS.....	58
5.3	SCIKIT-LEARN.....	58
5.4	PYTORCH.....	60
5.5	TENSORFLOW.....	61
6	METODOLOGIA	63
6.1	PROCESSAMENTO DOS DADOS.....	64
6.1.1	<i>Dados para teste</i>	66
6.2	TÉCNICA DE JANELA	67
6.3	ARQUITETURA DA REDE NEURAL RECORRENTE	68
7	RESULTADOS	71
7.1	CONJUNTO DE DADOS C1.....	71
7.2	CONJUNTO DE DADOS C2.....	72
7.3	ANÁLISES DA REDE NEURAL RECORRENTE PROPOSTA	72
7.3.1	<i>Análise na cidade de Indaial</i>	78
8	CONCLUSÕES	81
8.1	PROPOSTAS DE TRABALHOS FUTUROS	82
	REFERÊNCIAS	83
	ANEXOS	89
	ANEXO A – CONJUNTO DE DADOS.....	89

1 INTRODUÇÃO

A matriz elétrica nacional vem se expandindo ao longo dos anos, mantendo o foco em fontes renováveis de energia. Todavia, a diversificação do setor energético tem sido reforçada cada vez mais, diminuindo a participação de hidrelétricas e apostando em diferentes fontes renováveis. Dados do Balanço Energético Nacional (BEN) apontam que no ano de 2021 o país atingiu 78,1% de renovabilidade na matriz elétrica. Nesse cenário, a geração a partir de hidrelétricas apresentou uma queda na participação de 8,5%, enquanto outras apresentaram crescimento na participação, como a solar (55,9%), o gás natural (46,2%) e a eólica (26,7%) (BEN, 2022).

Ainda, com o aumento da demanda, o país apresentou um crescimento de 3,9% na capacidade instalada no ano de 2021. Nesse cenário, destacam-se a solar com uma variação na capacidade de 40,9% e a eólica com 21,2%. Ainda nessa perspectiva de mudanças, no ano de 2021 a micro e minigeração distribuída (MMGD) apresentaram um aumento significativo de 84% em relação ao ano de 2020. Nesse panorama, a solar ganha enorme destaque, sendo responsável por 88,3% da MMGD em 2021 (BEN, 2022).

Ao mesmo tempo que traz benefícios, o crescimento e a renovação da matriz elétrica impacta no aumento da complexidade do sistema elétrico de potência, em especial o sistema de distribuição de energia elétrica. Um dos fatores de maior impacto é o acréscimo de geração descentralizada, trazendo consigo vantagens como o uso de fontes renováveis, maior agilidade para atender demandas e redução de perdas técnicas. Por outro lado, aumenta-se a necessidade de análises rigorosas do comportamento do sistema diante das novas dinâmicas que o mesmo será submetido.

Frente a esse cenário, surge o conceito de redes inteligentes como adaptação as mudanças da rede elétrica. As redes inteligentes podem ser entendidas como redes elétricas que utilizam de medidores inteligentes bidirecionais, sendo dotadas de tecnologias digitais e recursos computacionais e de comunicação avançados que permitem o fluxo eficiente de informação entre geração e consumo. Assim, aprimora-se o monitoramento e gerenciamento da rede, fazendo com que o modelo seja considerado mais confiável, seguro, eficiente, econômico e sustentável. Ainda, equipamentos mais modernos permitem a adoção de técnicas mais sofisticadas para auxiliar na operação da rede elétrica, incluindo, por exemplo, a capacidade de prever

descontinuidades na geração de energia a partir de fontes renováveis, facilitando o controle e operação de sistemas mais complexos.

Nesse contexto, a inteligência artificial é uma das técnicas que vem se difundindo no mundo moderno, possuindo ainda muitos campos nos quais pode e deve ser explorada. Através de redes inteligentes e algoritmos de inteligência artificial, sistemas elétricos podem ser geridos de forma mais eficiente, permitindo decisões mais precisas que impactam diretamente na alocação dos recursos energéticos. Assim, a aplicação de inteligência artificial no setor energético representa uma solução para diversas problemáticas atuais, destacando-se a preocupação em acompanhar o crescimento de demanda em consonância com a melhoria da qualidade dos serviços prestados.

Na literatura, diversos métodos vêm sendo aplicados para previsão de variáveis relacionadas a geração solar de energia. Segundo Abedin *et al.* (2017), essa previsão pode ser realizada através de algoritmos de aprendizado de máquina, com modelos que consigam identificar padrões em grandes conjuntos de dados e assim, prover modelos preditivos de alta performance. Ainda, inúmeros trabalhos em diferentes áreas mostram que redes neurais artificiais apresentam boas soluções em diversos problemas práticos, como nas pesquisas desenvolvidas por Martins *et al.* (2016), Barreto *et al.* (2018) e Freitas *et al.* (2019). Na primeira pesquisa, Martins *et al.* (2016) desenvolveram um modelo para determinar o afilamento de fuste nas árvores de eucalipto. Já Barretos *et al.* (2018) aplicaram a técnica de redes neurais para diagnóstico de câncer cervical. Por fim, Freitas *et al.* (2019) empregaram as redes neurais no processo de classificação de neoplasias mamárias.

A justificativa deste trabalho se ampara na tendência futura da aplicação cada vez maior dessas ferramentas computacionais na resolução dos novos desafios advindos do desenvolvimento do sistema elétrico, dando-se destaque ao crescimento da geração solar fotovoltaica. O Brasil conta com altos níveis de radiação global que contribuem para que o país possua grande potencial de aproveitamento energético solar. Consequentemente torna-se interessante a aplicação de metodologias modernas na otimização desse tipo de sistema.

Assim, este trabalho tem por objetivo geral o estudo da aplicação de redes neurais artificiais na área de geração de energia. Por conseguinte, os objetivos específicos são:

- Estudos sobre a matriz energética, fontes renováveis e redes neurais artificiais;
- Levantamento bibliográfico da aplicação de redes neurais na previsão de geração de energia;
- Desenvolvimento e comparação de diferentes arquiteturas de redes neurais recorrentes para previsão de radiação solar global.

1.1 Estruturação do trabalho

Este trabalho é dividido em sete capítulos, dos quais faz parte a introdução. Os demais capítulos são:

- Capítulo 2 – Matriz energética e geração solar de energia: neste capítulo revisa-se a matriz energética brasileira, discorrendo dos recursos de geração e dando atenção especial as fontes renováveis de energia. Por fim, trata-se da geração solar de energia fotovoltaica e os modos de geração.
- Capítulo 3 – Redes neurais artificiais: neste capítulo trata-se das redes neurais artificiais e suas aplicações na previsão de geração solar de energia.
- Capítulo 4 – Redes neurais recorrentes: neste capítulo trata-se das redes neurais recorrentes, destacando os conceitos que envolvem a temática.
- Capítulo 5 – Linguagem de programação Python: neste capítulo trata-se da linguagem de programação *Python*, focando-se nas principais bibliotecas aplicadas no desenvolvimento de algoritmos de aprendizado de máquina.
- Capítulo 6 – Metodologia: neste capítulo foi apresentada a metodologia aplicada no desenvolvimento da rede neural artificial.
- Capítulo 7 – Resultados: neste capítulo discorre-se acerca dos resultados obtidos, expondo e comparando três configurações diferentes de arquitetura.
- Capítulo 8 – Conclusões: o capítulo final apresenta a conclusão do trabalho desenvolvido e propostas de trabalhos futuros.

2 MATRIZ ENERGÉTICA E GERAÇÃO SOLAR DE ENERGIA

O presente capítulo trata da matriz energética brasileira, abordando os conceitos e o panorama nacional, principalmente no que tange as fontes renováveis. Por fim, trata-se da energia solar e seus modos de geração.

2.1 Matriz energética brasileira e as fontes renováveis de energia

Reis (2017) cita que uma matriz energética consiste em uma série de recursos empregados por uma nação visando fornecer a energia requerida para a execução de processos produtivos. Há dois tipos de recursos que contemplam:

- Os primários, envolvendo as fontes de energia provenientes da natureza, isto é, as que não experimentam processos de transformação como é o caso de carvão mineral, gás natural e petróleo.
- Os secundários, constituídos através de uma matéria-prima que irá experimentar uma série de transformações como a eletricidade, o diesel, a gasolina, entre outros.

A matriz elétrica contempla somente a utilização de fontes de energia para que se tenha a geração da energia elétrica. A matriz energética, por sua vez, leva em consideração todas as destinações existentes como é o caso do uso em setores industriais e de transportes, por exemplo (CAMPOS, 2010).

Até o ano de 1970 o petróleo e a lenha respondiam por cerca de 80% de toda a demanda nacional. Porém, atualmente a matriz energética conta com a participação significativa de diversas outras fontes de energia, das quais 44,7% representam fontes renováveis (biomassa, hidráulica, lenha e carvão vegetal e outras renováveis). Nesse cenário a participação do petróleo e derivados foi de 34,4% e a lenha 8,7% (EPE, 2022).

Fiorotti (2019) aponta que há a divisão das fontes de energia em dois grupos, as renováveis e as não renováveis. As não renováveis são as que estão presentes de

modo limitado na natureza, ou seja, tendem a extinguir. Entre os principais exemplos, aponta-se:

- O urânio.
- O carvão mineral.
- O gás natural.
- O petróleo.

Os recursos não renováveis têm como vantagem o fato de se ter uma ampla experiência no processo de geração da energia por meio deles, além da facilidade em se promover o transporte e o armazenamento. Porém há desvantagens, a maior delas se liga à possibilidade de esgotamento, existe também o fato de que as maiores reservas estão situadas em regiões dotadas de política instável como é o caso do Oriente Médio e, por fim, a queima desses produtos tende a resultar no lançamento de parcelas elevadas de dióxido de carbono na atmosfera, especialmente em comparação com os recursos renováveis, atenuando assim o efeito estufa (MAMEDE FILHO, 2021).

Sá (2010) cita que ao se tratar de fontes renováveis, destaca-se que nesse grupo há os recursos que podem ser repostos pela natureza, no entanto, o consumo não pode ser superior à capacidade natural que o planeta tem de produzi-lo. Há uma série de recursos renováveis empregados para a geração de energia, os principais contemplam:

- O hidráulico.
- O eólico.
- A biomassa.
- O solar.

O aumento na utilização das fontes renováveis se deu por volta dos anos de 1990, mas ganhou destaque somente no século XXI devido à elevação da preocupação com as questões ambientais, as alterações periódicas no valor do barril de petróleo e a redução na quantidade de reservas de combustíveis fósseis em determinadas nações (LOUREIRO *et al.*, 2021).

No começo do século XXI o Brasil experimentou uma crise energética elevada, entre os anos de 2000 e 2002 vivenciou-se um momento em que se tinha a possibilidade de cortes forçados no abastecimento energético. Esses eventos marcantes foram chamados de apagões e resultou em grandes preocupações por

parte da população e do governo. Além disso mostrou um descaso com o setor devido aos investimentos reduzidos na área de geração e de distribuição de energia (GANIM, 2019).

No ano de 2002 foi criado o chamado Programa de Incentivo às Fontes Alternativas de Energia visando expandir a utilização de outros meios de geração de energia a fim de ampliar a matriz energética nacional. Em um primeiro momento fomentou-se a criação de projetos envolvendo pequenas centrais hidrelétricas, energia eólica e biomassa. Em seguida determinou-se que em 20 anos a matriz energética nacional deveria contar com, pelo menos, 10% de fontes renováveis (CREDER, 2021).

2.2 Radiação Solar e Geração de Energia

A radiação solar é a energia eletromagnética provinda do Sol e propaga-se em todas as direções através do espaço. É um recurso importante que provém luz e calor para o planeta bem como energia, além de ser responsável por determinar dinâmicas atmosféricas e climatológicas. Como tal, pode ser aproveitada de diversas formas, como geração de calor em processos industriais e domésticos e geração de eletricidade. A radiação solar pode ser definida de quatro formas, conforme a maneira que chega ao planeta:

- **Radiação Solar Difusa:** radiação recebida indiretamente devido ao processo de difração devido a obstáculos na atmosfera (nuvens, poeira, etc).
- **Radiação Solar Direta:** radiação recebida diretamente através dos raios solares, sem sofrer qualquer dispersão durante o trajeto.
- **Radiação Solar Refletida:** parcela da radiação proveniente da reflexão na superfície terrestre
- **Radiação Solar Global:** radiação total que atinge uma superfície, sendo composta pela soma da radiação difusa, direta e refletida.

A radiação solar pode ser medida por sua potência energética por unidade de área, sendo watts por metro quadrado. Obter dados de radiação solar é importante em diversos âmbitos, destacando-se:

- Estudo da transformação de energia no sistema Terra-Atmosfera.
- Estudo da distribuição de radiação incidente em suas diferentes formas.
- Operação e melhoria de desempenho em sistemas de energia solar.
- Previsão de disponibilidade de radiação para sistemas fotovoltaicos.

Nesse sentido, conhecer o comportamento da radiação solar permite o entendimento da disponibilidade do recurso solar para os mais diversos processos, destacando-se a geração de energia. A seguir discorre-se acerca da energia solar objetivando contextualizar a introdução da produção de energia solar a nível mundial, abordando também o cenário energético solar nacional e, por fim, elucidando o processo de geração de energia através dos diferentes modos disponíveis.

2.2.1 Energia Solar

A partir de 2001 intensificou-se os esforços para utilizar a radiação solar para a geração de energia elétrica. Nações desenvolvidas como Alemanha e Japão foram as pioneiras no estudo de tal possibilidade por causa da elevação da preocupação ambiental com a utilização de combustíveis fósseis e de energias não renováveis, além do incremento do preço do barril de petróleo (BARROS *et al.*, 2015).

Há duas tecnologias principais empregadas no aproveitamento de energia solar, os painéis fotovoltaicos e os concentradores de calor. No que tange aos painéis fotovoltaicos, menciona-se que estes adotam os efeitos fotoelétricos para promover a conversão da radiação solar na eletricidade. Em vista do exposto, não há a queima de combustíveis fósseis, não há a produção de cinzas e não há a liberação do calor ao longo do processo (BALFOUR *et al.*, 2016).

O físico francês Alexandre Edmond Becquerel foi um dos pioneiros na pesquisa do efeito fotovoltaico, descobrindo, no ano de 1839, que se pode extrair energia elétrica através da energia solar. Posteriormente, no ano de 1954, as células fotovoltaicas foram criadas nos Estados Unidos da América, na ocasião empregava-se o silício como o elemento semicondutor para a célula do material. Por esse motivo

cerca de 98% da geração de energia solar mundial adota a tecnologia dos painéis fotovoltaicos (KALOGIROU, 2016).

A energia fotovoltaica também emite gases do efeito estufa, porém, esses produtos são advindos, em grande parte dos casos, das atividades destinadas à extração e ao preparo de minérios empregados para a fabricação dos painéis, bem como da distribuição e das instalações destinadas ao armazenamento da energia gerada no processo. Pode-se mencionar que o processo de geração propriamente dito irá emitir níveis extremamente baixos (ou não emite) gases nocivos ao meio ambiente, por essa razão é tida como uma energia limpa (PEREIRA *et al.*, 2017).

A concentração do calor, denominada ainda como tecnologia heliotérmica faz o uso de espelhos que atuam concentrando a irradiação solar. No emprego dessa tecnologia, inicialmente há a geração de energia térmica, depois disso ocorre a transformação em mecânica e, após isso obtém-se a energia elétrica. A maior vantagem de tal processo se liga ao fato de ser possível armazenar o calor para ser usado em qualquer período (inclusive nos períodos noturnos) (MOREIRA, 2017).

Na contemporaneidade os custos de utilização da energia solar reduziram de forma considerável, potencializando assim a capacidade instalada em todo o mundo. Desde o ano de 2019, a energia solar está entre as fontes mais competitivas no mercado brasileiro. Ainda assim, a fonte ainda representa uma pequena contribuição em relação as demais fontes presentes na matriz elétrica nacional (ABSOLAR, 2022).

A diminuição nos custos de geração de fontes renováveis pode se dar por meio da obtenção das matérias-primas para a produção das células a custos mais atrativos, além de melhorias nas tecnologias que tendem a contribuir para a diminuição dos custos da instalação e também para potencializar a eficiência. No ano de 2020 a energia solar correspondeu a 1,7% de toda a energia gerada na matriz energética nacional, um valor pequeno, mas que tem crescido de modo considerável nos últimos anos (RUTTER *et al.*, 2020).

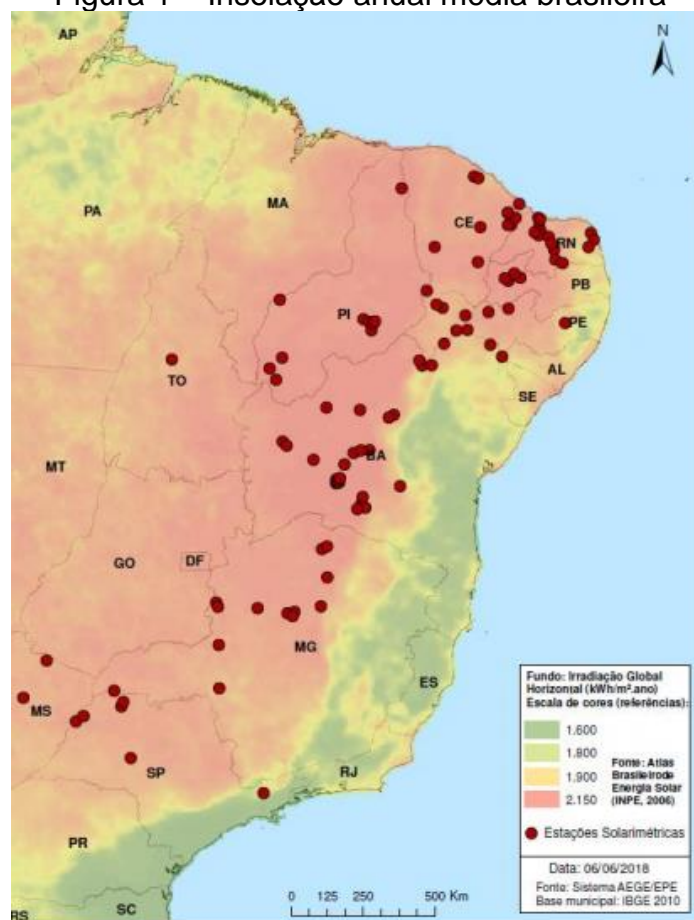
2.2.2 Geração solar de energia elétrica

O Brasil é uma nação favorecida no que tange à utilização da energia solar, pois se encontra localizado perto da região terrestre denominada intertropical, o que

resulta em variações de energia mais baixas durante as mais variadas estações de um ano. Merece destaque ainda o fato de que alguns estados se encontram localizados perto da Linha do Equador, o que propicia mínimas variações na energia solar. Em contrapartida existem outros estados que se encontram perto do Trópico de Capricórnio, região dotada de elevadas variações de energia solar (KALOGIROU, 2016).

A Figura 1 ilustra o potencial da energia solar que o Brasil apresenta, evidenciando a insolação média anual no território nacional. Aponta-se que no Norte e no Nordeste do país tem-se incidências maiores de radiação solar e uma das razões disso se liga ao fato de estarem perto da linha do Equador.

Figura 1 – Insolação anual média brasileira



Fonte: EPE (2020)

A energia solar é um recurso que traz consigo uma série de benefícios para todos que se encontram ao longo da sua cadeia produtiva como os consumidores, as empresas de energia elétrica, os geradores e o meio ambiente. A razão disso se relaciona com os baixos impactos ambientais e os custos mais atrativos, além de não

apresentar ruídos e poluição durante a sua utilização. Através dela é possível também reduzir o número de linhas de transmissão que há no Brasil, diminuindo assim a poluição visual advinda dos cabos dos sistemas de distribuição (RODRIGUES *et al.*, 2013).


Por meio da redução das linhas de distribuição é possível minimizar as falhas em potencial que é comum nesses elementos. Diante disso a diminuição de falhas impede uma série de outros problemas como o desabastecimento que faz com que haja a falta de energia elétrica nos centros consumidores. Além disso a energia solar traz consigo uma possibilidade de geração de mais empregos, da reorganização da matriz energética brasileira, além da redução no emprego dos combustíveis fósseis (ROSA, 2014).

Evidencia-se que um dos anos mais importantes para a energia solar no Brasil foi 2021, com um crescimento de 49% em relação a investimentos acumulados até o final do ano de 2020. Com todo o investimento o país também teve um aumento de 65% em geração de empregos na área em relação ao acumulado entre os anos de 2012 a 2020. Dessa forma, a energia solar aumentou sua participação para 2,4% na matriz elétrica, passando a ser a sexta maior fonte de energia a nível nacional (ABSOLAR, 2022).

Nesse cenário, uma energia limpa, sustentável e renovável tem conquistado espaço no Brasil, isso é demonstrado através dos números que apontam o aumento da sua competitividade em comparação com outras fontes energéticas. No mês de março de 2022, o Brasil transcendeu a marca 900 mil sistemas fotovoltaicos conectados à rede de geração distribuída, sendo aproximadamente 922 mil pontos de consumo que adotam essa tecnologia em solo nacional (ANEEL, 2022).

Segundo a ANEEL os sistemas de micro e minigeração distribuída contam com uma potência instalada superior a 10 GW, sendo a fonte solar fotovoltaica responsável por 99% da capacidade. Outro ponto que merece atenção é que, aproximadamente 97% das cidades brasileiras apresentam, no mínimo, um sistema fotovoltaico ligado à rede (HEIN, 2021). A Figura 2 mostra a matriz elétrica brasileira, pode-se perceber que a fonte solar ocupa a sexta posição nesse caso.

Figura 2 – Matriz elétrica brasileira em janeiro de 2022



*A potência total da matriz não inclui a importação.


Fonte: ANEEL/ABSOLAR (2022)

De acordo com Moreira (2017), no Brasil existem diversas usinas que produzem a energia solar, grande parte delas estão situadas em estados do Sudeste, do Noroeste e do Norte. No entanto, os que se destacam são Minas Gerais e São Paulo com os maiores índices de geração nacional. Fazer o uso de tal fonte permite agregar uma série de vantagens para todos os agentes ligados à cadeia produtiva da energia, as principais são:

- O aumento nos investimentos nas atividades de transmissão e de distribuição de energia elétrica.
- A redução dos impactos ao meio ambiente.
- A criação de novos postos de trabalho.
- A minimização das perdas elétricas presentes nas redes nacionais.
- O alívio de sistemas elétricos nos horários de pico, principalmente no verão.
- A redução dos gastos atrelados à energia elétrica.
- A captura de novos investimentos, especialmente os advindos do poder privado.

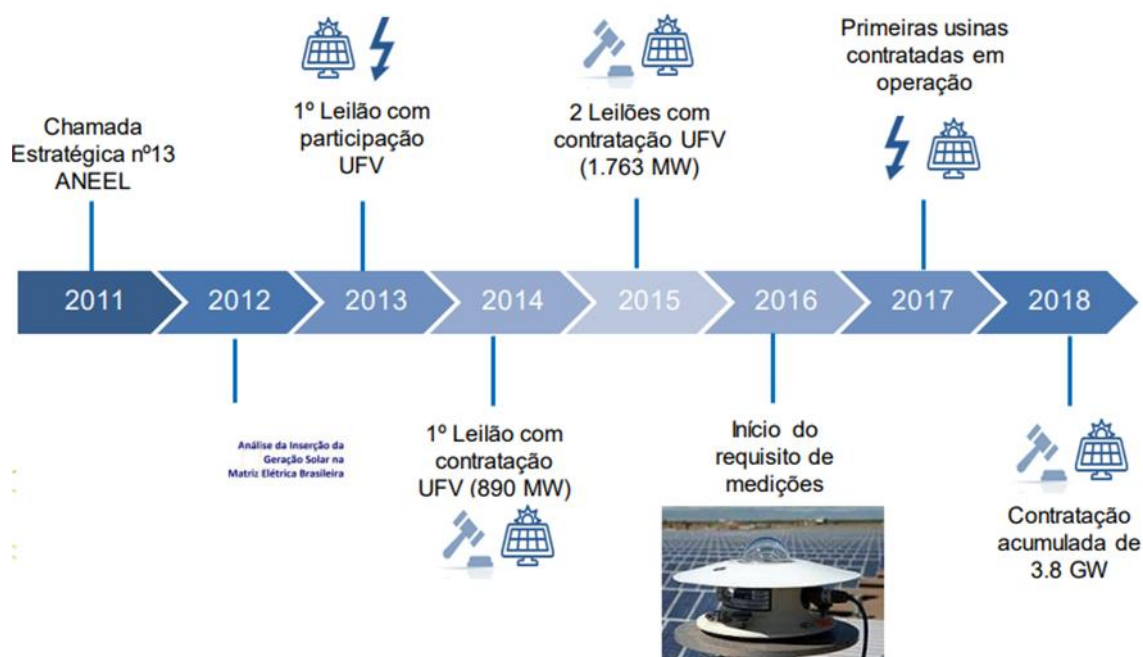
Frente a esse cenário, aponta-se que a quantidade de políticas públicas que fomentam a utilização e a geração de energia solar no Brasil tem aumentado de forma

considerável. Segundo Paixão (2019) os estímulos por parte do governo têm gerado diversos empregos diretos e indiretos, além da redução nos custos da energia gerada por tal fonte. Em determinados casos os valores da energia gerada através do sol têm se mostrado mais reduzido em comparação com outras fontes de energia alternativas como é o caso da biomassa e das pequenas centrais hidrelétricas, como mostra a Figura 3.



Houve um aumento na quantidade de energia fornecida através da energia solar, entre os anos de 2019 e 2021 realizaram-se cerca de seis leilões contemplando a geração de energia por meio de tal fonte. Portanto, tem-se notado um grande incremento na matriz energética brasileira no que se refere à geração de energia elétrica através das fontes renováveis. Aponta-se ainda que a energia solar é tida como a segunda fonte de geração de energia mais barata no território brasileiro, o que tende a fomentar ainda mais a sua disseminação (RUTTER *et al.*, 2020). Dessa forma, a Figura 4 aponta o marco histórico da energia solar em território nacional entre os anos de 2011 e 2018.

Figura 4 – Marco histórico da energia solar em território nacional entre os anos de 2011 e 2018



Fonte: EPE (2020)

Espera-se que nos próximos anos haja a redução dos custos com a energia fotovoltaica, o que contribuirá mais ainda para que tal fonte conquiste espaço na matriz energética nacional. Ainda, o interesse nessa área vem aumentando significativamente, destacando-se a geração distribuída que só no ano de 2021 acumulou investimentos que transcendem os 21,8 bilhões de reais (ABSOLAR, 2022).


2.2.3 Modos de geração de energia solar fotovoltaica

Existem duas formas principais de gerar energia solar que são os modos *on-grid* e *off-grid*. No modelo *on-grid* ou conectado à rede faz-se o uso de uma série de equipamentos para gerar a energia como é o caso dos painéis fotovoltaicos e os inversores da corrente. Nesse caso, se o empreendimento precisar da energia disponível que foi produzida, utilizará a energia da rede, pois o excedente gerado é injetado diretamente na rede (SILVA, 2015).

Caso a unidade consumidora necessite de energia fornecida pela companhia de eletricidade será possível obtê-la, uma vez que a energia passará por um relógio que se encontra na entrada do ponto de consumo. A Figura 5 mostra os principais

equipamentos adotados no processo de geração, evidencia-se que por meio dessa estratégia é possível gerar energia tanto em sistemas centralizados, como nos descentralizados (BARROS *et al.*, 2015).

Figura 5 – Sistema fotovoltaico *on-grid*




Fonte: Adaptado de Tecnoblog (2021)

O sistema *on-grid* permanece ligado à rede de distribuição da companhia de maneira integral, dessa forma, quando não se tem a produção da energia, faz-se o uso da rede da concessionária. No entanto, a partir do momento em que a produção é superior à utilização, injeta-se o excedente na rede, com isso geram-se créditos que servirão como um elemento para o abatimento no valor da fatura de energia. A vantagem nesse caso é a capacidade que se tem de não utilizar baterias solares, o que simplifica o sistema (KALOGIROU, 2016).

Quanto ao sistema *off-grid* ou sistema autônomo, pode-se citar que a geração ocorre através de uma série de componentes que trabalham de forma integrada. Esses modelos requerem o uso de componentes extras em relação ao modo *on-grid*, como as baterias e os controladores de carga (SOUZA *et al.*, 2020).

Os sistemas autônomos são muito utilizados em regiões remotas, em espaços rurais, entre outros locais, uma vez que tendem a apresentar custos mais acessíveis para a obtenção de energia nesses casos. Vale mencionar que tal metodologia possibilita também a realização de uma série de atividades como a movimentação de veículos, a iluminação de residências, entre outras coisas (REIS, 2017). Nesse cenário, a Figura 6 mostra de modo esquemático o sistema de funcionamento da geração da energia solar fotovoltaica *off-grid*.

Figura 6 – Sistema fotovoltaico *off-grid*



Fonte: Adaptado de Tecnoblog (2021)


3 REDES NEURAIS ARTIFICIAIS

A seguir discorre-se acerca das redes neurais no processo de previsão de variáveis relacionadas a geração de energia solar fotovoltaica .

3.1 Redes neurais artificiais (RNA)

As RNAs consistem em modelos de processamento de dados que tem como base uma semelhança com uma estrutura biológica neural. Aponta-se que nesse caso tem-se ferramentas estatísticas que, através de exemplos, conseguem aprender, bem como armazenar as informações de modo a apresentar as melhores soluções partindo do conhecimento adquirido (HAYKIN *et al.*, 2000). Diante disso, a Figura 7 apresenta um neurônio biológico

Figura 7 – Neurônio biológico



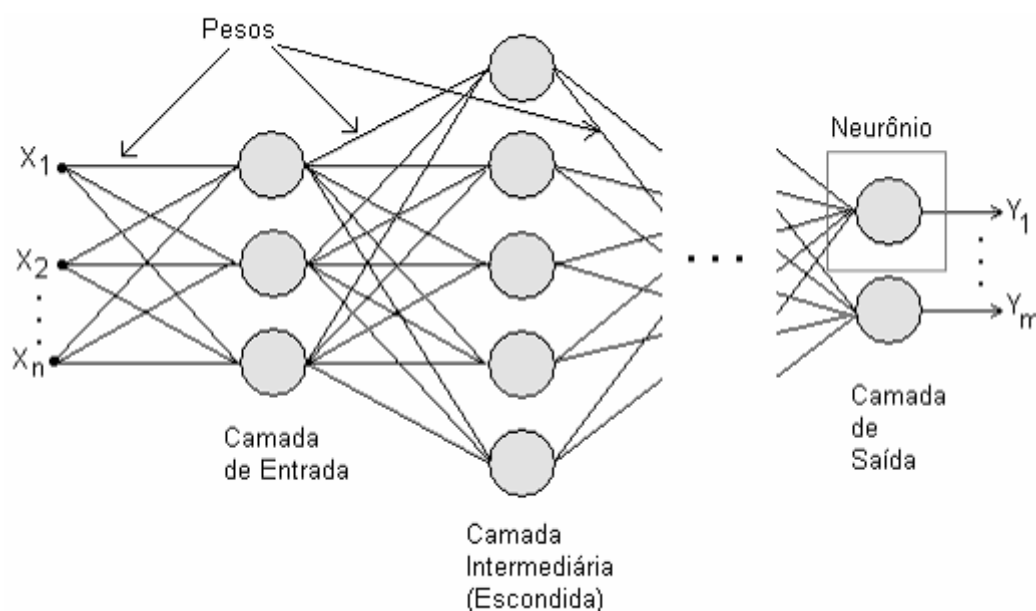
Fonte: Minussi (2008)

O neurônio biológico é formado basicamente por:

- Corpo celular: parte central do neurônio onde os impulsos nervosos são gerados.
- Sinapse: é uma região de proximidade entre o axônio de um neurônio e o dendrito de outro. Assim, são responsáveis por controlar a transmissão de impulsos entre neurônios.
- Dendrito: são responsáveis por receber as informações de outros neurônios e transmiti-las para o corpo celular.
- Axônio: parte responsável pela condução dos impulsos que partem do corpo celular para locais mais distantes, podendo ter poucos milímetros até um metro.

Tomando como base o cérebro humano e o sistema nervoso biológico conceberam-se as RNAs, instrumentos constituídos por uma série de unidades de processamentos mais simples chamadas neurônios artificiais. Esses componentes consistem em processadores distribuídos de forma paralela e que contam com a capacidade de acondicionar o conhecimento experimental de maneira a disponibilizá-lo para a utilização (RUSSELL; NORVIG, 2013). Na Figura 8 exemplifica-se o esquema de uma rede neural artificial.

Figura 8 – Esquema de uma rede neural artificial



Fonte: Minussi (2008)

De acordo com Geron (2021) as RNAs são muito parecidas com o cérebro humano por conta de duas questões. A primeira é que por meio do processo de

aprendizagem consegue-se fazer com que a rede obtenha o conhecimento, a segunda ocorre, pois o armazenamento das informações se dá nas forças de conexão que há entre os neurônios, nos chamados pesos sinápticos. Vale mencionar que se concebeu as redes neurais artificiais tendo como base a biologia do cérebro humano. Nesses casos partiu-se de alguns pressupostos que são:

- Cada um dos neurônios conta com a função da ativação na sua entrada, sendo que normalmente, não é linear, com isso é possível definir o sinal na saída, bem como a capacidade de se ter a ativação ou não.
- Há a organização dos neurônios em camadas que se encontram devidamente interligadas. Nesses casos transmite-se os sinais entre os neurônios através de uma série de conexões, denominadas sinapses, sendo que em tais conexões associam-se os valores, chamados de pesos sinápticos.
- O processamento dos dados se dá em simples unidades que são intituladas nós ou neurônios que contam com a capacidade de computar as funções do tipo matemáticas, principalmente as não lineares.

Aponta-se que cada uma das entradas que são recebidas pelos neurônios é devidamente ponderada pelos chamados pesos sinápticos que irão acondicionar o conhecimento que é devidamente representado por uma RNA. Evidencia-se que antes de se ter alguma solução para o problema há o treinamento, isto é, existe o momento de aprendizagem em que se tem a apresentação de uma ampla variedade de informações em rede (SILVA, 2016).

Pelo motivo destacado anteriormente é que se tem o ajuste nos pesos da conexão até que obtenha uma capacidade de se adaptar aos problemas em investigação. Depois da fase de treinamento promove-se a fixação dos dados, possibilitando assim que se tenha um modelo responsável pela estimação das saídas levando em conta uma ampla infinidade de informações na entrada (SEJNOWSKI, 2020). Vale ressaltar que durante o processo de aprendizado, pode-se diferenciar a rede neural quanto a forma que a mesma se relaciona com o ambiente, de acordo com dois paradigmas:

- Aprendizado supervisionado: nesse tipo de aprendizado de máquina, o treinamento é realizado a partir de exemplos rotulados. Assim, a rede terá um indicador de “certo” e “errado”, aprendendo conforme os dados que foram fornecidos. Esse tipo de aprendizado é comumente aplicado em problemas de classificação e regressão.

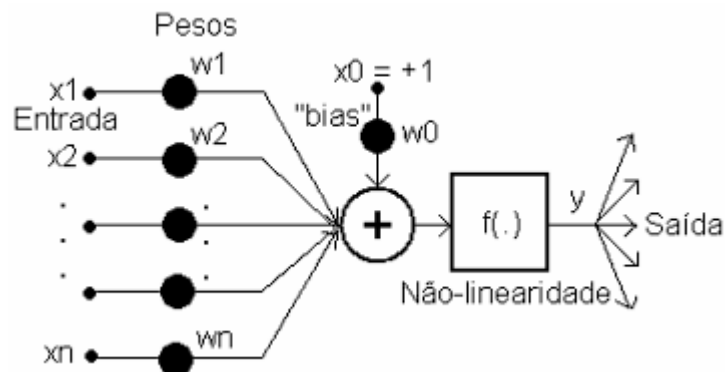
- Aprendizado não supervisionado: nesse caso, o algoritmo não possui exemplos rotulados para indicar a resposta desejada. Assim, o aprendizado ocorre através da identificação de padrões e características em comum dos dados utilizados. Esse tipo de aprendizado pode ser encontrado em problemas de *clustering*, que visa o agrupamento de dados conforme grau de semelhança.

Existem diversas razões que fundamentam a utilização de RNAs, porém, a principal delas tem como base a capacidade de processar algo temporalmente, bem como da auto-organização, da generalização e do reconhecimento dos padrões. Isso tende a viabilizar a resolução de uma série de eventos dotados dos mais variados níveis de complexidade, tudo com excelentes resultados, especialmente nos eventos que contam com um nível de não linearidade elevado. Contudo, é essencial ter em mente que as redes neurais artificiais não apresentam o mesmo grau de eficiência para todos os problemas existentes (LUDWING JUNIOR; MONTGOMERY, 2020).

Os neurônios artificiais foram introduzidos inicialmente por McCulloch e Pitts (1943), utilizando tal conceito na pesquisa denominada “*A logical calculus of the ideas immanent in nervous activity*”. O trabalho integrado desenvolvido pelo neuro atomista e psiquiatra McCulloch, em consonância com o matemático Pitts possibilitou a concepção das RNAs. O modelo criado contava com entradas iguais a x_i em que o i corresponde a 1, 2, 3, ..., n , equivalendo às informações da entrada da rede ou então a saída de outros neurônios. Nesse caso ponderavam-se os pesos sinápticos do tipo não ajustáveis equivalentes a w_i contendo $i = 1, 2, 3, \dots, n$.

Frente ao exposto, destaca-se que no modelo concebido por McCulloch e Pitts (1943) há a determinação da soma dos produtos das entradas x_i por pesos w_i . A soma alimenta uma função não linear $f(.)$ que produz o sinal de saída que será enviado aos demais neurônios. O neurônio citado também pode conter um peso de viés w_0 , que controla o nível de saída do modelo (MINUSSI, 2008). Na Figura 9 apresenta-se o modelo de RNA proposto por McCulloch e Pitts.

Figura 9 – Modelo de RNA criado por McCulloch e Pitts



Fonte: Minussi (2008)

Após o trabalho publicado por McCulloch e Pitts foram desenvolvidas outras pesquisas acerca do assunto, sendo que a mais relevante foi o livro intitulado “*The Organization of Behavior de Hebb*”, publicado no ano de 1949. Na ocasião esse foi o primeiro método destinado ao treinamento das RNAs que tinha como postulado o fato de que a aprendizagem é um processo eficiente de sinapse que varia entre dois neurônios, no qual se tem uma ativação repetitiva do neurônio, devidamente causada por outro através da sinapse (HAYKIN *et al.*, 2000).

Rosenblatt (1958) desenvolveu a chamada rede neural Perceptron que era constituída pelos neurônios criados anteriormente, com a diferença de que era possível ajustar os vieses e os pesos sinápticos, permitindo assim a classificação de padrões que são separáveis linearmente. Com isso, emergiu o modelo denominado Perceptron com uma única camada.

Widrow e Hoff (1960) conceberam a rede denominada *Adaptive Linear Elemento* (Adaline) que se distinguia do modelo criado anteriormente quanto ao modo de aprendizagem. Na rede Adaline, durante a fase de aprendizado os pesos são ajustados de acordo com a soma ponderada das entradas. Posteriormente, adaptou-se o algoritmo para uma rede de múltiplas camadas, chamado *Many-Adaline* (Madaline). A rede Madaline é uma arquitetura de três camadas (entrada, oculta e saída) totalmente conectadas do tipo feed-forward que aplica unidades Adaline em suas camadas. Três diferentes algoritmos de treinamento para a rede Madaline foram propostos ao longo dos anos, sendo:

- **Madaline Rule 1 (MR-I):** foi proposto no ano de 1962, sendo baseado no algoritmo de treinamento Adaline de 1960. No MR-I a mudança baseou-se na

atualização dos pesos apenas para as camadas ocultas da rede. Assim, os pesos das camadas de saída permanecem fixos.

- **Madaline Rule II (MR-II):** a segunda proposta foi descrita no ano de 1987, como um aprimoramento do MR-I. No MR-II todos os pesos da rede são atualizados, incluindo na camada de saída.
- **Madaline Rule III (MR-III):** a terceira adaptação do algoritmo foi proposta em 1988, substituindo a função de ativação binária pela função sigmoide. Posteriormente, descobriu-se que a adaptação é matematicamente equivalente ao algoritmo de retro propagação.

Minsky e Papert (1969) mostraram as principais limitações das redes neurais dotadas de camada única como era o caso da Perceptron e da Adaline em seu livro, chamado *“Peceptrons – An Introduction to Computational Geometry”*. Os pesquisadores evidenciam as impossibilidades de se classificar de modo adequado os padrões das classes que não são separáveis do ponto de vista linear, o que culminou na diminuição significativa da quantidade de publicações associadas à temática.

No trabalho desenvolvido por Hopfield (1982) o princípio de armazenamento dos dados em redes neurais estáveis dinamicamente foi devidamente mencionado pela primeira vez. Ainda na década de 80, o livro *“Neural networks and physical systems with emergent collective computational abilities”* de Rumelhart e McClelland (1986), ajudou a fomentar a adoção da aprendizagem por retro propagação. No mesmo ano, Rumelhart *et al.* (1986) elaboraram um artigo denominado *“Learning representations by backpropagation errors”* com o algoritmo do processo de aprendizagem pela chamada retro propagação. Na ocasião apresentou-se tal instrumento, bem como se propôs o seu uso para que as máquinas pudessem aprender, propiciando assim a demonstração do funcionamento dessa ferramenta.

As redes neurais trazem consigo uma série de possibilidades, isso implica que é possível utilizá-las em vários campos de conhecimento. Por essa razão executou-se diversas pesquisas acerca da temática, como as desenvolvidas por Martins *et al.* (2016), Barreto *et al.* (2018) e Freitas *et al.* (2019). Martins *et al.* (2016) empregaram esse campo para determinar o afilamento de fuste nas árvores de eucalipto. Barreto *et al.* (2018) evidenciaram como as RNAs podem ser aplicadas com sucesso a um processo de tomadas de decisões em uma clínica especializada no diagnóstico do câncer cervical. Por fim, Freitas *et al.* (2019) empregaram tal instrumento como um

elemento responsável por ajudar no processo de classificação das neoplasias mamárias, o que lhes permitiu obter excelentes resultados, ao mesmo tempo em que se evidenciou a eficiência dos modelos.

Assim, apresentou-se alguns exemplos da aplicação das RNAs em vários campos de trabalho. A seguir, discorre-se acerca do uso dessa ferramenta na previsão de geração de energia solar fotovoltaica e variáveis relacionadas.

3.2 Redes neurais artificiais na previsão da geração de energia fotovoltaica

Na energia solar a previsão de produção possibilita planejar adequadamente o sistema, assegurando a realização de uma série de fatores atrelados ao processo de gerenciamento energético (SILVA, 2016). Frente a esse cenário, aponta-se que uma série de estratégias adotando as RNAs têm sido concebidas e empregadas no processo de avaliação e de previsão de disponibilidade dos recursos atrelados à energia solar.

Soares *et al.* (2004) adotaram as chamadas redes perceptrons de múltiplas camadas (MLP) para modelar a radiação solar difusa horária no município de São Paulo. Os autores apontaram que os valores de irradiação da onda longa, a umidade relativa, a irradiação global solar em superfície e a irradiação solar de topo da atmosfera são parâmetros indispensáveis nos modelos de RNAs para a previsão de geração de energia solar. Os pesquisadores concluíram que a pressão atmosférica e a temperatura do ar não impactavam a confiabilidade e a precisão estimada, além disso evidenciaram que é possível empregar as informações da irradiação da onda longa caso não haja dados disponíveis acerca da nebulosidade.

Já na pesquisa feita por Mellit *et al.* (2005) adotou-se as redes neurais artificiais da tipologia *Radial Basis Function*, com isso, foi possível determinar de forma satisfatória a quantidade de energia solar gerada. Na ocasião buscou-se ainda prever as séries temporais da radiação solar global diária, o que favoreceu a obtenção de informações como os valores de duração do brilho do sol e a temperatura do ar para um período igual a um ano.

Krishnaiah *et al.* (2007) fizeram o uso das redes neurais artificiais na previsão da geração de energia solar fotovoltaica na Índia e constataram que tal estratégia é

uma excelente ferramenta computacional quando se deseja estimar a chamada radiação solar global horária. Com isso, tem-se uma ótima metodologia para que se possa efetuar a modelagem de problemas mais complexos e que contam com definição mais difícil, independentemente da área.

Lopes (2010) afirma que na previsão da geração e da irradiação de energia solar tem-se metodologias e modelos embrionários, ao contrário do que ocorre no processo de previsão dos ventos no qual há modelos mais evoluídos e eficientes. Ao se tratar dos modelos empregados na avaliação das demandas associadas à geração de energia solar, aponta-se que os modelos mais usuais contemplam as informações meteorológicas e as imagens de satélites para a predição de energia. Isto posto, é possível encontrar na literatura especializada acerca do tema cerca de quatro horizontes de tempo que propiciam a predição da geração de energia:

- Os de muito curto prazo em que se tem uma previsão na qual o horizonte do tempo tende a oscilar entre alguns segundos a até uma hora. Tal tipologia é realizada com a ajuda das informações obtidas no local em que se quer efetuar a previsão.
- Os de curto prazo, contemplando as previsões contendo um horizonte temporal que está situado em um intervalo que vai de uma hora a até 7 dias.
- Os de longo prazo que englobam uma previsão que conta com um horizonte de tempo situado de 7 dias a até mesmo vários anos. Aponta-se que tal estratégia tem como base as simulações de recursos energéticos.
- Os de muito longo prazo que envolvem um modo de previsão dotado de um horizonte temporal superior a dezenas de anos. Nesse caso, tem-se uma forma de previsão de recurso solares pautado em estudos que tratam de modificações climáticas.

Santos (2010) concebeu uma abordagem para predizer a geração de energia solar fotovoltaica tendo como base duas fases diferentes, no primeiro caso adota-se as redes neurais artificiais para apontar qual foi a evolução temporal de nuvens em um período de tempo. Desse modo, na primeira etapa conseguiu-se prever a radiação global, além da radiação solar na região em que o sistema destinado à aquisição das imagens se encontrava localizado. Em um segundo momento da metodologia, criou-se um modelo tendo como base as RNAs visando promover a conversão de valores da radiação solar (previstos previamente na etapa anterior) em outro adequado à potência gerada por meio de uma instalação fotovoltaica em um período de cinco

minutos. Aponta-se que tudo isso ocorreu levando em consideração os impactos de outros eventos climáticos.

Diante disso Santos (2010) constatou que sua modelagem forneceu resultados excelentes para o caso em estudo. Além disso apontou que a relação existente entre a produção dos componentes em investigação e a radiação solar não ocorre puramente de modo linear. A adoção dos RNAs no estudo possibilitou a não adoção de modelos paramétricos que tem como desvantagem o fato de necessitarem da qualidade das informações fornecidas pelas companhias fabricantes. Outro ponto que merece atenção é que o emprego da inteligência artificial para determinar a produção da central foi atingido somente graças à presença de informações acerca do histórico da geração em uma série de informações históricas nas mais variadas condições meteorológicas para o funcionamento do gerador.

Já Andrade (2020) evidencia que prever a geração de energia elétrica em um intervalo de tempo traz consigo inúmeras vantagens. No curto prazo, por exemplo, consegue-se apontar quais são os efeitos e os custos atrelados à capacidade estimada, bem como das trocas energéticas. Além disso é possível obter informações que auxiliam na realização de medidas corretivas ou preventivas nos casos de operações econômicas e seguras nos sistemas elétricos de potência, por exemplo.

Silva (2016) reforça que a previsão acerca da geração de energia fotovoltaica é um processo complexo. A razão disso se liga a várias questões, sendo a principal delas a natureza oscilante dos climas como as alterações de temperatura, a movimentação das nuvens, entre outros fatores. No entanto, tal complexidade pode ser minimizada com a adoção de redes neurais recorrentes, por exemplo, que tendem a apresentar ótimos resultados em aplicações distintas.

Coutinho *et al.* (2016) adotaram as chamadas redes neurais artificiais da tipologia perceptrons de camadas múltiplas, bem como a função radial de base para efetuar a previsão em um passo à frente de uma ampla gama de informações meteorológicas. Efetuou-se ainda uma comparação dos métodos com os modelos dotados de regressão linear múltipla, o que permitiu constatar que as redes neurais artificiais do tipo função radial de base e de camadas múltiplas são essenciais para a geração de informações muito parecidas com a realidade.

Abdel-Nasser e Mahmoud (2017), por sua vez, sugerem a adoção das chamadas *Long Short-Term Memory Recurrent Neural Network* (LSTM RNN) ou redes neurais com memória de longo prazo. Por meio dessa metodologia consegue-se efetuar a

modelagem de mudanças que ocorrem nas informações em um dado tempo, tudo isso devido às unidades de memória e à arquitetura recorrente. Aponta-se que o LSTM RNN foi concebido para impedir que se tenha o problema ligado à dependência no longo prazo, ao contrário do que ocorre em redes neurais recorrentes convencionais. Portanto, tem-se uma ferramenta capaz de capturar os conceitos abstratos em uma sequência geracional da energia fotovoltaica.

Mendes *et al.* (2017) fizeram o uso das medições meteorológicas fornecidas pelo chamado Sistema de Organização Nacional de Dados Ambientais (SONDA) entre os meses de julho e de agosto do ano de 2016 considerando um intervalo de 1 minuto visando prever a energia solar global com o auxílio de redes neurais artificiais. Na ocasião empregou-se a RNA da tipologia MLP contendo três camadas e que foi treinada por meio do algoritmo denominado *backpropagation*.

Pinheiro *et al.* (2017) desenvolveram um estudo visando compreender o aproveitamento de recursos atrelados à energia solar, na ocasião focou-se na previsão da geração da energia elétrica de um sistema fotovoltaico, deixando de lado a estimativa da incidência da radiação solar. O modelo atingiu um coeficiente de correlação maior do que 0,98, evidenciando assim que as redes utilizadas possibilitam atingir resultados satisfatórios no caso em estudo.

Su *et al.* (2019) realizaram um trabalho de implementação em que se investigou e comparou o aprendizado em cerca de 10 algoritmos distintos de uma máquina no processo de previsão da geração de energia solar fotovoltaica considerando seis dias de antecedência. Aponta-se que os algoritmos englobam cerca de seis redes neurais recorrentes, bem como quatro metodologias de inteligência artificial que são:

- O *Support Vector Regression*.
- O *Random Forest*.
- O *Extreme Learning Machine*.
- O *K Nearest Neighbours*.
- O *Nonlinear Autoregressive Neural Network with Exogenous Inputs*.
- O *Adaptive Network based Fuzzy Inference System*.
- O *Generalized Regression Neural Network*.
- O *Elman Neural Network*.
- O *Back Propagation Neural Network with Genetic Algorithm Optimization*.
- O *Back Propagation Neural Network*.

Su *et al.* (2019) apontam que há uma infinidade de algoritmos que podem contribuir para o aprendizado das máquinas no que tange à predição da geração da energia solar fotovoltaica. Os autores reforçam que as abordagens utilizadas no aprendizado das máquinas, normalmente, tendem a ser superiores em comparação com os tradicionais métodos estatísticos por causa das habilidades intrínsecas que possibilitam a modelagem de não linearidades, bem como de processos dinâmicos e complexos.

Su *et al.* (2019) reforçam ainda que os modelos desenvolvidos não fornecem as informações em quantidades adequadas acerca do modo de determinação da metodologia. Portanto, a literatura que discorre acerca das redes neurais artificiais para prever a geração de energia solar fotovoltaica carece de um método relevante. Outro ponto que merece atenção é que as pesquisas levam em conta uma série de instalações reais distintas, apresentando várias especificações do conjunto de dados, das condições climáticas, dos períodos, dos locais e das plantas, reforçando assim que não existe um modo consistente e padrão para determinar quais são as métricas de erro e do treinamento do modelo.

4 REDES NEURAIS RECORRENTES

O presente capítulo apresentará os principais termos e estratégias presentes nos algoritmos de redes neurais, em especial as redes neurais recorrentes.

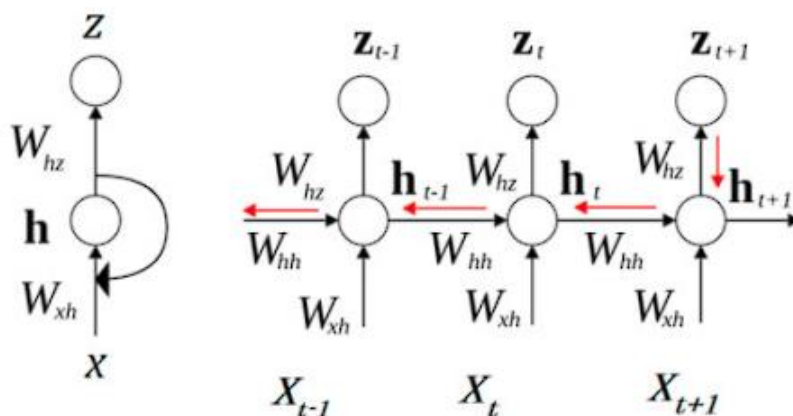
4.1 Rede neural recorrente

A rede neural recorrente tem por objetivo mimetizar o comportamento do cérebro humano, mantendo na memória informações sobre o passado. Nesse aspecto, dados anteriores servem de auxílio para o entendimento de dados atuais. Tal característica permite que a rede lide com dados que possuam ligação temporal.

As redes recorrentes recebem informações de dois instantes de tempos: uma do presente e outra de um tempo passado. Ambas as fontes serão utilizadas na tomada de decisão quando exposta a novas entradas de dados, operação essa realizada por um circuito de retroalimentação. Essa característica possibilita que a rede neural recorrente reconheça o contexto temporal através da memória (ZAREMBA; SUTSKEVER; VINYALS, 2014).

Na Figura 10 exemplifica-se a estrutura de uma rede neural recorrente.

Figura 10 – Modelo rede neural recorrente



Fonte: Hiransha et al. (2018)

No diagrama, a equação de entrada da rede é dada por:

$$h_t = g_n(W_{xh}X_t + W_{hh}h_{t-1} + b_h) \quad (1)$$

Em que:

- h_t é a camada intermediária no instante t ;
- g_n é a função de ativação;
- W_{xh} é a matriz de pesos das entradas;
- X_t é a entrada no instante t ;
- W_{hh} é a matriz de pesos dos neurônios recorrentes;
- h_{t-1} é a camada intermediária no instante $t-1$;
- b_h é o viés.

A equação de saída, por sua vez, é dada pela equação a seguir:

$$Z_t = g_n(W_{hz}h_t + b_z) \quad (2)$$

Em que:

- Z_t é o vetor de saída;
- W_{hz} é a matriz de pesos para a camada de saída;
- b_z é o viés.

4.2 Conceitos

Nesta seção serão abordados os principais conceitos que envolvem as redes neurais artificiais, dando destaque as técnicas que foram posteriormente adotadas no desenvolvimento da rede neural recorrente proposta neste trabalho.

4.2.1 Treinamento e Teste

A coleta de dados relativos ao problema que se estuda é a primeira parte no desenvolvimento de uma rede neural. Após essa etapa, deve-se ter dois conjuntos de dados (treinamento e teste) que servirão respectivamente para realizar o treinamento do modelo e avaliar o modelo realizando-se previsões. Ainda, quanto a divisão desses conjuntos, deve-se ter um volume de dados grande o suficiente para garantir que ambos os conjuntos sejam representações adequadas do problema.

Assim, cada problema necessita de uma quantidade de dados que dependerá da complexidade do processo observado. Com o conhecimento do problema tratado, pode-se entender a quantidade adequada de dados para garantir uma representação apropriada considerando-se também o aspecto de eficiência computacional. Dessa forma, preocupa-se com o aspecto de otimização da rede partindo-se do pré-processamento dos dados.

Frente a isso, define-se o procedimento de divisão do conjunto de dados em três subconjuntos, sendo:

- Subconjunto de treinamento: utilizado para ajustar o modelo durante o período de treinamento.
- Subconjunto de validação: utilizado para validar o modelo durante o período de treinamento.
- Subconjunto de teste: utilizado para realizar as previsões de teste após obter o modelo treinado, avaliando assim a capacidade de predição da rede neural.

4.2.2 Época

Segundo Brownlee (2018) o número de épocas é um hiperparâmetro que definirá o número de vezes que o algoritmo de aprendizado será executado para o conjunto de dados do treinamento da rede. Ainda inclui-se a estratégia de divisão do conjunto de dados em uma mesma época em diversos lotes, denominado *batch size*.

4.2.2.1 Tamanho do lote

Segundo a Data Science Academy (2022) o tamanho do lote (*batch size*) é um termo utilizado em aprendizado de máquinas que se refere ao número de amostras utilizadas para cada atualização de pesos. O tamanho do lote pode assumir três modos distintos:

- **batch mode:** o tamanho do lote é igual ao tamanho do conjunto de dados, tornando a atualização de pesos igual ao número de épocas;
- **mini-batch mode:** o tamanho do lote é maior que um, porém menor que o número de amostras do conjunto de dados. Usualmente, o valor é um divisor do tamanho do conjunto.
- **stochastic mode:** o tamanho do lote é igual a um, logo a atualização dos pesos é realizada após cada amostra.

4.2.3 Células


A escolha da célula a ser empregada no algoritmo é parte fundamental do processo de definição da arquitetura da rede neural. Nesta seção serão abordadas as principais células recorrentes e seu funcionamento.

4.2.3.1 Célula Long Short-Term Memory (LSTM)

A célula LSTM é uma arquitetura de rede neural recorrente para aprendizado com dependências de longo prazo, sendo projetada para evitar o problema de desaparecimento do gradiente. O gradiente é valor utilizado para atualização dos pesos sinápticos e quando esse valor se torna pequeno, diminui sua contribuição para o aprendizado da rede neural. Assim, as células LSTM se tornam adequadas para

classificação, processamento e previsão de séries temporais. Na Figura 11 apresenta-se a configuração de uma rede LSTM.

Figura 11 – Modelo célula LSTM



Fonte: Wikipedia contributors (2017)

Da Figura 11, formula-se as equações matemáticas que representam o funcionamento lógico das células LSTM:

$$I_t = \sigma(W_{xi}X_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (3)$$

$$F_t = \sigma(W_{xf}X_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (4)$$

$$c_t = F_t \times c_{t-1} + I_t \times \tanh(W_{xc}X_t + W_{hc}h_{t-1} + b_c) \quad (5)$$

$$O_t = \sigma(W_{xo}X_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (6)$$

$$h_t = O_t \times \tanh(c_t) \quad (7)$$


Em que c_t é o estado atual da célula, c_{t-1} o estado anterior, I_t um *input gate*, O_t um *output gate* e F_t o *forget gate*.

O estado da célula carrega a informação da célula anterior para a atual, passando por toda a estrutura da rede. Nesse processo, o *forget gate* será responsável pela decisão de guardar ou não a informação no estado da célula. No *input gate* serão adicionadas informações uteis ao estado da célula, sendo a informação regulada por uma função sigmoide. No *output gate* serão extraídas as informações do estado da célula para serem apresentadas como uma saída.

4.2.3.2 Célula Gated Recurrent Unit (GRU)

A célula GRU é uma arquitetura de célula recorrente similar a LSTM, porém sua estrutura é simplificada. Enquanto a célula LSTM conta com três tipos de portões, a GRU dependerá de dois portões: *update gate* e *reset gate* (CHO et al., 2014). Devido a menor complexidade, as células GRU são treinadas mais rapidamente, porém podem apresentar resultados inferiores quando expostas a um grande volume de dados. Na Figura 12 apresenta-se a configuração de uma rede GRU.

Figura 12 – Modelo célula GRU



Fonte: Wikipedia contributors (2017)

Da Figura 12, formula-se as equações matemáticas que representam o funcionamento lógico das células GRU:

$$Z_t = \sigma(W_x X_t + U_z h_{t-1} + b_z) \quad (8)$$

$$R_t = \sigma(W_r X_t + U_r h_{t-1} + b_r) \quad (9)$$

$$\tilde{h}_t = \tanh(W_h X_t + U_h (R_t \times h_{t-1}) + b_h) \quad (10)$$

$$h_t = (1 - Z_t) \times h_{t-1} + Z_t \times \tilde{h}_t \quad (11)$$

Em que Z_t representa o vetor do *update gate* e R_t o vetor do *reset gate*.

O *reset gate* é derivado da entrada oculta do estado anterior e atual da célula. Ao passar pelo treinamento da rede, os pesos serão atualizados permitindo que esse

vetor retenha apenas os recursos uteis. No *update gate*, o cálculo é realizado utilizando as mesmas variáveis do anterior, diferenciando-se na matriz de pesos. Do *update gate*, o modelo determinará as informações que serão retidas para as operações futuras.

4.2.4 Normalização dos dados

Os dados de entrada em uma rede neural estão comumente em intervalos de variação bastante distintos, impactando negativamente no processo de treinamento e aprendizado. Isto ocorre devido a interpretação errônea da rede, dando maior importância a valores elevados em detrimento de valores menores. Para contornar o problema, é usual que os dados passem pelo processo de normalização, delimitando os atributos de entrada a limites reduzidos, conforme a função de ativação aplicada.

4.2.5 Algoritmo otimizador

No processo de aprendizado, a rede neural passa por diversas atualizações de pesos. Para tal, o desempenho da rede deve ser continuamente testado pela comparação entre o resultado obtido e o esperado. Assim, o objetivo do algoritmo otimizador é minimizar o resultado da função de perda, que retorna valores positivos, e tende a zero na medida que a saída se aproxima ao resultado esperado (TAQI et al., 2018).

Segundo Ruder (2016) o gradiente descendente é um dos algoritmos mais utilizados na otimização em redes neurais. A técnica consiste no cálculo do gradiente da função de custo, em relação ao parâmetro θ , para todo conjunto de dados de treinamento, expressando-se da seguinte forma:

$$\theta = \theta - \eta \nabla_{\theta} J(\theta) \quad (12)$$

Em que η representa a taxa de aprendizagem e $J(\theta)$ a função objetivo que se pretende minimizar. Diversas bibliotecas de aprendizado de máquina possuem implementações otimizadas dessa técnica de descida do gradiente.

Este trabalho aplica o algoritmo Adam de otimização, razão pela qual se dará enfoque ao algoritmo no qual o mesmo se baseia (RMSprop) e suas especificidades.

4.2.5.1 Algoritmo RMSprop

O RMSprop foi proposto por Hinton et al. (2012), sendo um método de taxa de aprendizagem adaptativa que utiliza o sinal do gradiente, adaptando o tamanho de passo individualmente para cada peso. O algoritmo essencialmente mantém uma média móvel do quadrado do gradiente, realizando a divisão do gradiente pela raiz desta média. Dada a definição, as equações abaixo elucidam o processo de otimização:

$$E[g^2]_t = 0,9E[g^2]_{t-1} + 0,1g_t^2 \quad (13)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} \cdot g_t \quad (14)$$

Em que g é o gradiente da função de custo, $E[g^2]$ é a média móvel dos quadrados dos gradientes, η é a taxa de aprendizagem e ϵ um termo que evita o problema de divisão por zero.

4.2.5.2 Algoritmo Adam

O algoritmo Adam foi proposto em Kingma e Ba (2014), sendo um método que utiliza as médias móveis dos gradientes e também dos quadrados dos gradientes na atualização dos parâmetros. As médias são iniciadas em zero e calculadas conforme as equações

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (15)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (16)$$

Em que m_t é o vetor das médias dos gradientes no instante de tempo t , v_t é o vetor das médias dos quadrados dos gradientes no instante de tempo t , g_t é o gradiente da função de custo, β_1 é o peso atribuído a média dos gradientes e β_2 o peso atribuído a média do quadrado dos gradientes.

No entanto, Ruder (2016) destaca que os valores m_t e v_t tendem a solução a zero, principalmente quando os valores dos pesos atribuídos se aproximam de um. Para contornar o problema, os valores dos vetores são corrigidos conforme as equações

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (17)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (18)$$

Em que \hat{m}_t representa o vetor corrigido das médias dos gradientes, \hat{v}_t representa o vetor corrigido das médias dos quadrados dos gradientes, e β^t são os pesos elevados a quantidade de épocas da rede neural. Assim, a atualização dos parâmetros será calculada pela equação

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \quad (19)$$

Em que θ é o vetor de pesos, η é a taxa de aprendizagem e ϵ um valor que evita o problema da divisão por zero.

4.2.6 Taxa de aprendizagem

A taxa de aprendizagem é um hiperparâmetro do algoritmo de otimização que determina o tamanho do passo a cada iteração da rede em direção a minimização da função de custo (Murphy, 2012). Quanto menor o valor, mais lento é o processo de

decaimento do gradiente. Assim, valores menores garantem uma varredura mais eficaz em busca do mínimo da função de custo. Em contrapartida, o algoritmo de otimização levará um tempo maior para convergir.

4.2.7 Avaliação

No processo de aprendizado de redes neurais, alguns critérios de acurácia são adotados para aferir o poder preditivo do modelo treinado. A literatura aborda diversas técnicas estatísticas para avaliar o desempenho através da análise estatística dos resultados obtidos. Em suma, o erro de um modelo de aprendizado de máquina é calculado pela comparação entre o valor real (Y) e o previsto (\hat{Y}). Dentre as técnicas disponíveis destacam-se o Erro Médio Quadrático (MSE), a Raiz do Erro Médio Quadrático (RMSE), a Média do Erro Absoluto (MAE), a Média do Erro Absoluto Percentual (MAPE) e o coeficiente de determinação (R^2). A seguir, discorre-se sobre cada uma dessas técnicas.

4.2.7.1 MSE

O erro médio quadrático é comumente utilizado na verificação de acurácia de modelos de previsão. Essa métrica é calculada pela equação

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (20)$$

Em que n mensura a quantidade de amostras do conjunto de dados, Y_i é o valor real da variável a ser prevista, e \hat{Y}_i é o valor previsto pelo modelo.

Visto que cada erro é elevado ao quadrado, o modelo dará maior peso a erros maiores. Assim, a métrica se torna sensível a valores discrepantes, não se adequando em análises que contenham muitos erros significativos.

4.2.7.2 RMSE

A raiz do erro médio quadrático pode ser obtida pelo cálculo da raiz quadrada do MSE. Com essa particularidade, o valor do erro retorna a mesma unidade de medida da variável analisada, mantendo a ideia de penalização de erros maiores. A métrica é obtida pela equação

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (21)$$

4.2.7.3 MAE

O erro médio absoluto apresenta a distância entre o valor previsto e o valor real, não diferenciando erros negativos e positivos. Diferente das métricas anteriores, o cálculo do MAE não penaliza valores discrepantes. Expressa-se pela equação

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (22)$$

4.2.7.4 MAPE

O erro médio absoluto percentual demonstra a porcentagem de erro em relação aos valores reais do conjunto de dados. Expressa-se pela equação

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{\max(\epsilon, |Y_i|)} \quad (23)$$

Em que ϵ é um valor muito pequeno que evita a divisão por zero.

4.2.7.5 R^2

O coeficiente de determinação R^2 representa a proporção da variância nas previsões realizadas pelo conjunto de dados. Calcula-se através da equação

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (24)$$

Em que \bar{Y} é a média dos valores do conjunto de dados.

De forma geral, quanto mais próximo de 1, mais explicativo é o modelo em relação aos valores previstos. No entanto, essa métrica isolada não permite uma avaliação global do problema, sendo ideal sua aplicação em conjunto a outras técnicas apresentadas. Ainda, na interpretação dessa métrica deve-se atentar as seguintes questões:

- O R^2 possui relação com a quantidade de preditores de um modelo. Quanto mais preditores, maior o R^2 . Assim, a comparação desse parâmetro se torna útil em problemas com a mesma quantidade de preditores.
- O cálculo do R^2 será mais preciso quando calculado para uma quantidade maior de amostras. Conjuntos pequenos de amostras não fornecerão uma estimativa precisa da relação entre os dados reais e as previsões.
- O coeficiente de determinação mede apenas o grau de ajuste do modelo aos dados expostos. Assim, torna-se interessante a verificação gráfica do modelo de forma a complementar a análise.

4.2.8 Função de Ativação

As funções de ativação respondem pela não linearidade das redes neurais artificiais. A ausência desse método implica em uma rede linear, limitando-a as mesmas restrições de modelos lineares. Isto posto, torna-se essencial a utilização dessa estratégia com o intuito de conferir a capacidade não linear no processo de aprendizado da rede. Conforme Ceccon (2020) essas funções idealmente aplicam-se considerando-se algumas características:

- Operações não lineares possuem maior custo computacional. O incremento desse custo é impactante, especialmente em redes com uma quantidade maior de dados e ciclos de treinamento.
- O treinamento de redes neurais através da descida do gradiente implica na derivação de todas as operações matemáticas. Assim, as funções de ativação devem ser obrigatoriamente diferenciáveis.
- A função deve ser centrada em zero, possuindo iguais probabilidades de produzir respostas positivas ou negativas. Caso contrário, o resultado seguirá uma única direção, dificultando a convergência do algoritmo.
- A função não pode tender a regiões constantes. Tais regiões implicam que a derivada tenderá a zero, causando o problema de explosão do gradiente. Assim, o gradiente tenderá a zero e a rede perderá a capacidade de convergir.

A seguir, discorre-se das principais funções de ativações aplicadas a redes neurais.

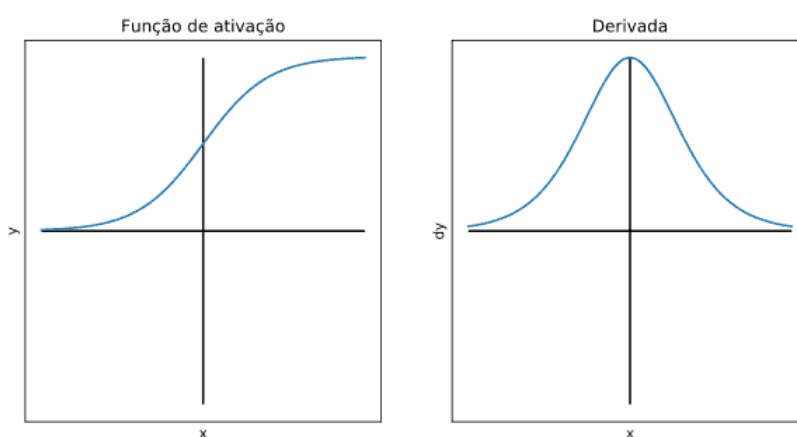
4.2.8.1 Função Sigmoid

Segundo Nwankpa (2018) a função sigmoide, também referenciada na literatura como função logística, é uma função não linear utilizada principalmente em redes neurais *feedforward*. Possui característica diferenciável limitada, definida para valores reais de entrada e com resultados positivos de derivação em toda região. É expressa pela equação

$$f(x) = \frac{1}{(1 + \exp^{-x})} \quad (25)$$

A função sigmoide é comumente aplicada em camadas de saída de arquiteturas utilizadas em classificação binária e modelos de regressão logística. No entanto, deve ser evitada para redes iniciadas a partir de pequenos pesos aleatórios. A Figura 13 ilustra a função sigmoide e sua derivada.

Figura 13 – Função Sigmoide



Fonte: Ceccon (2020).

Da Figura observa-se que a função sigmoide possui algumas desvantagens, sendo uma função não centrada em zero e que assume caráter constante para valores maiores. Assim, pode apresentar convergência lenta ou não convergência para determinados problemas.

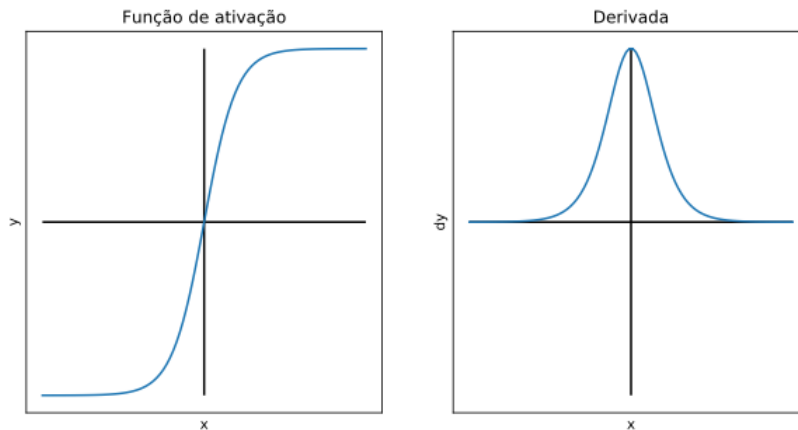
4.2.8.2 Função Tangente Hiperbólica

A função tangente hiperbólica foi proposta como alternativa a função sigmoide, sendo uma função centrada em zero cujo intervalo se encontra entre $[-1, 1]$. É expressa pela equação

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (26)$$

A Figura 14 ilustra a função tangente hiperbólica e sua derivada.

Figura 14 – Função Tangente Hiperbólica



Fonte: Ceccon (2020)


4.2.8.3 Função ReLU

A função *rectified linear unit* (ReLU) foi proposta por Nair e Hinton (2010). Segundo Ramachandran et al. (2017), é a função mais aplicada e com os melhores resultados encontrados na literatura recente. Além do melhor desempenho, oferece melhor generalização no processo de aprendizado em comparação com as funções anteriores. A ReLU é uma função quase linear, preservando as propriedades dos modelos lineares, simplificando sua otimização em problemas que aplicam o método de gradiente descendente. A função é obtida através da equação

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{se } x_i \geq 0 \\ 0, & \text{se } x_i < 0 \end{cases} \quad (27)$$

A principal vantagem do método é o baixo custo computacional. Além disso, a função retifica os valores de entrada negativos, forçando-os a zero e eliminando o problema de explosão do gradiente. A Figura 15 ilustra a função ReLU e sua derivada.

Figura 15 – Função ReLU




Fonte: Ceccon (2020)

4.2.9 Técnica de Janela

As entradas da rede neural podem conter uma ou mais variáveis. Além disso, deve-se atentar a quantidade de termos de cada variável que serão utilizados para prever o próximo termo. Tal característica de arranjo dos dados é denominada de técnica de janela.


Na técnica da janela, define-se um período n que corresponde a quantidade de dados passados que serão utilizados para prever o dado futuro. Para entradas genéricas $\{x_1, x_2, x_3, \dots, x_n\}$, onde deseja-se prever o próximo termo usando apenas o termo anterior, define-se um período igual a um. Assim, a rede terá o seguinte aspecto conforme a Figura 16.

Figura 16 – Técnica da janela de um período



Fonte: Elaborada pelo autor

No entanto, problemas mais complexos podem depender de um número maior de amostras anteriores para realizar melhores previsões. Dessa forma, a rede pode conter n períodos, conforme a Figura 17.

Figura 17 – Técnica da janela de n períodos

Fonte: Elaborada pelo autor

Por conseguinte, percebe-se que para períodos maiores que um, cada entrada deve conter informações de pelo menos n termos anteriores ao termo previsto.

4.2.10 Critério de parada

A literatura aborda diversos métodos para a determinação do momento em que o treinamento da rede deve ser encerrado. Tal definição é de extrema importância no que tange a eficácia e boa generalização do algoritmo treinado. Entre os critérios de parada, pode-se destacar:

- **Número de épocas:** neste método, define-se a quantidade de épocas que a rede executará o treinamento. Assim, quando o algoritmo atingir o valor máximo de épocas, o treinamento é encerrado.
- **Erro:** neste método, a rede encerrará o treinamento quando o erro da previsão ficar abaixo de um limiar definido. Nesse cenário, o valor de erro que se objetiva irá variar de acordo com as características do problema.
- **Combinação dos métodos anteriores:** nesse caso, o treinamento será interrompido quando um dos critérios for atendido, seja o número máximo de épocas ou o erro abaixo do requerido.
- **Early Stop:** no método de parada antecipada, a cada n épocas o treinamento é interrompido para realizar a verificação de erro. Caso a rede não apresente melhorias nesse intervalo, o treinamento é finalizado. Neste método pode-se descobrir o momento em que a rede perdeu seu poder de generalização.

5 LINGUAGEM DE PROGRAMAÇÃO PYTHON

No aprendizado de máquina, a linguagem de programação Python possui ampla aplicação, com diferentes bibliotecas focadas na temática que garantem o desenvolvimento de ferramentas computacionais eficientes. No que diz respeito ao desenvolvimento de redes neurais, destacam-se as seguintes bibliotecas:

- NumPy
- Pandas
- Scikit-learn
- PyTorch
- TensorFlow

Nas seguintes subseções serão abordadas as funcionalidades das diferentes bibliotecas citadas

5.1 NumPy

A biblioteca *NumPy* foi criada em 2005 por Travis Oliphant, objetivando uma ferramenta para processamento de vetores. Assim, a *NumPy* aplica-se para processamento otimizado de matrizes multidimensionais. Os conceitos de vetorização, indexação e transmissão da biblioteca *NumPy* estabelecem o padrão da computação matricial na linguagem Python, servindo de base para diferentes bibliotecas como a *scikit-learn* e *SciPy*.

Ainda, a biblioteca oferece diversas ferramentas numéricas computacionais de alta performance, com operações rápidas para o tratamento e manipulação de dados, geração e filtragem de conjuntos. A seguir, citam-se as principais vantagens da utilização da biblioteca *NumPy* em relação as opções nativas para armazenamento de dados em Python:

- Memória: a biblioteca aplica o conceito de localidade de referência, onde os dados são armazenados em um bloco contínuo de memória. Dessa forma, aumenta-se a eficiência do acesso e modificação dos dados.

- Velocidade: as operações podem ser realizadas sem a necessidade da utilização de laços, permitindo processamentos mais complexos de forma mais rápida quando comparadas com operações nativas da linguagem.
- Facilidade: a disponibilidade de diversas operações entre matrizes como soma, subtração, transposição e interpolação para aplicação em problemas na área de aprendizado de máquinas, processamento de imagens e rotinas de cálculo.

5.2 Pandas

A biblioteca Pandas foi desenvolvida inicialmente no ano de 2008 pela AQR Capital Management, tornando-se *open source* a partir de 2009. A biblioteca fornece ferramentas para análise e manipulação de dados com alta flexibilidade e eficiência (Pandas, 2022). É considerada a principal e mais completa biblioteca para manipulação de dados, sendo amplamente aplicada nos estudos de aprendizado de máquinas. Os principais destaques da biblioteca são:

- O objeto DataFrame com indexação integrada que permite a manipulação rápida e eficiente dos conjuntos de dados;
- Ferramentas para leitura e gravação de dados em diferentes formatos: CSV, arquivos de texto, bancos de dados SQL e HDF5;
- Otimização para alto desempenho;
- Aplicação para uma ampla variedade de problemas, incluindo estatística, neurociência e finanças.

5.3 Scikit-learn

A *scikit-learn* é uma biblioteca *open source* focada em aprendizado de máquina da linguagem Python. O projeto foi iniciado em 2007 por David Cournapeau, sendo posteriormente parte da tese de Matthieu Brucher. Todavia, o primeiro lançamento

público do projeto se deu no ano de 2010, sendo liderado por Fabian Pedregosa, Gael Varoquaux, Alexandre Gramfort e Vincent Michel.

A biblioteca compreende uma variedade de algoritmos de aprendizado de máquinas supervisionados e não supervisionados, utilizando-se de uma interface orientada por tarefas, permitindo a comparação entre diferentes metodologias para aplicação diversas (Pedregosa et al., 2011). Entre as vantagens da biblioteca, citam-se a facilidade de uso, o desempenho e a vasta documentação.

A Didática Tech (2022) evidencia que a *scikit-learn* pode ser dividida em módulos distintos, conforme as finalidades das funções presentes, organizando-se da seguinte forma:

- Pré-processamento: funções especializadas no tratamento dos dados que alimentarão o algoritmo de aprendizado de máquina. Entretanto, normalmente essa etapa é realizada por bibliotecas como NumPy e Pandas.
- Classificação: módulo com funções para desenvolvimento de algoritmos de classificação, onde objetiva-se detectar a qual categoria diferentes amostras do conjunto de dados pertence.
- Regressão: módulo com funções para solução de problemas de regressão, como por exemplo, previsão de preço de imóveis e ações.
- Clusterização: módulo com funções para desenvolvimento de algoritmos de aprendizado para identificação de padrões em conjuntos de dados.
- Redução de dimensão: funções para redução de variáveis com o objetivo de reduzir a quantidade de cálculos realizados com mínimas perdas na assertividade do modelo.
- Ajuste de parâmetros: funções para comparar e escolher diferentes parâmetros e modelos, facilitando a busca pela melhor configuração de determinada aplicação.

5.4 PyTorch

A biblioteca PyTorch é uma das principais bibliotecas de aprendizado de máquina, tendo sido desenvolvida em 2016 pelo laboratório de inteligência artificial Meta AI, pertencente ao conglomerado multinacional de tecnologia Meta Platforms. A biblioteca é *open source*, sendo aplicada para implementações de aprendizado profundo e processamento de linguagem natural. O pacote trabalha com matrizes multidimensionais chamadas de tensores e desenvolvimento de redes neurais profundas.

A biblioteca também pode ser utilizada para cálculos matemáticos complexos, contribuindo com a possibilidade da aceleração de GPU, permitindo a otimização através da utilização da unidade processamento gráfico do computador. Usualmente, a biblioteca pode ser utilizada como:

- Substituição a biblioteca NumPy, visando a aceleração de GPU;
- Plataforma de desenvolvimento de algoritmos de aprendizado profundo com máxima flexibilidade e velocidade.

Os tensores utilizados pela biblioteca *PyTorch* podem ser entendidos como um contêiner de dados de múltiplas dimensões. Matematicamente, um tensor é a unidade fundamental de dados utilizada para realizar as operações matemáticas avançadas. A principal vantagem do formato em relação ao utilizado pela biblioteca *NumPy* é a possibilidade da manipulação através da GPU. Os principais módulos da biblioteca são:

- Autograd: módulo de diferenciação do *PyTorch* que auxilia no cálculo dos gradientes;
- Optim: pacote com algoritmos pré-escritos para otimizadores utilizados na construção da rede neural artificial;
- nn: módulo principal, possuindo diversas classes para a construção do modelo de rede neural.

5.5 TensorFlow

A biblioteca *TensorFlow* possui papel semelhante a biblioteca *PyTorch*, sendo utilizada na construção de modelos de aprendizado profundo. O projeto foi desenvolvido originalmente por pesquisadores e engenheiros da equipe Google Brain. A biblioteca possui flexibilidade para uma ampla variedade de aplicações. O *TensorFlow* é um framework *open source* para as linguagens Python e JavaScript. A biblioteca permite a execução através de diferentes plataformas, incluindo CPUs, GPUs e TPUs.

Assim como o *PyTorch*, os dados são matrizes multidimensionais chamadas de tensores. A principal diferença entre as duas bibliotecas está na dualidade simplicidade e desempenho. Enquanto *PyTorch* é considerada uma biblioteca mais fácil de ser aplicada, o *TensorFlow* possui melhor desempenho, sendo a biblioteca mais utilizada na prática. A arquitetura TensorFlow pode ser dividida em três partes distintas:

- Pré-processamento de dados;
- Construção do modelo;
- Treino e avaliação do modelo.

A biblioteca utiliza-se do conceito de grafos para o fluxo de dados. As principais vantagens da utilização de grafos durante a construção do modelo são:

- Portabilidade: um grafo pode ser salvo para uso posterior, podendo ser executado em diferentes plataformas como CPU, GPU, TPU e até mesmo aplicações *mobile*.
- Otimização: o grafo pode ser transformado para produzir versões mais otimizadas em diferentes plataformas.
- Suporte a execução distribuída.

Ainda, os principais algoritmos presentes no pacote são:

- Regressão linear;
- Classificação;
- Classificação com Aprendizado Profundo;
- Combinação de Regressão e Classificação com Aprendizado Profundo;
- Árvore de regressão;

- Árvore de classificação.

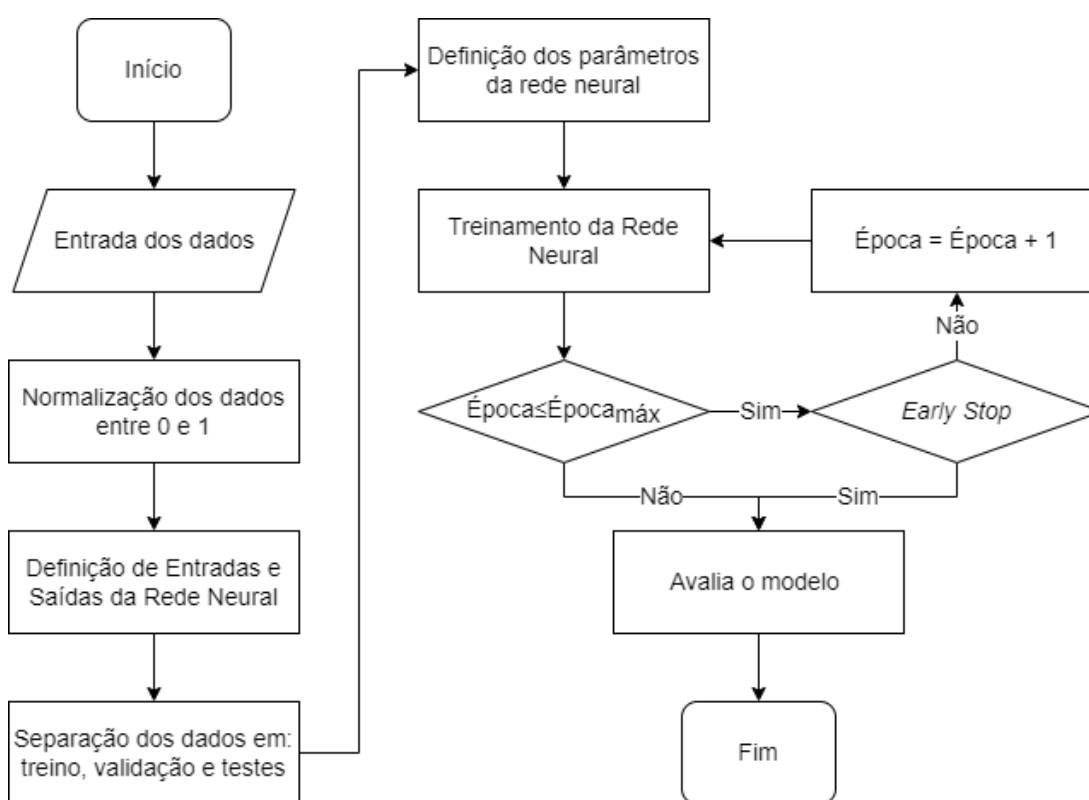
Por fim, o *TensorFlow* conta com a *Application Programming Interface (API) Keras* para treinamento e avaliação de modelos de aprendizado de máquina. De acordo com a documentação do *TensorFlow*, a *Keras* é uma API de alto nível para construir e treinar modelos com prototipagem rápida. A API possui interface simplificada e *feedback* de erros, facilitando a programação de modelos complexos de aprendizado de máquina. A API *Keras* ainda apresenta uma variedade de funções de ativação e métricas de acurácia para otimizar os modelos criados no framework *TensorFlow*. Dentre as principais vantagens da utilização da API, citam-se:

- Modelos pré-definidos de diferentes células neurais, entre elas as células recorrentes (por exemplo: LSTM e GRU);
- Presença das principais técnicas para avaliação do modelo, como MAE e RMSE;
- Possibilidade da aplicação simplificada de técnicas sofisticadas como *Early Stop* e *Dropout*;
- Funções de otimização baseadas no gradiente descendente.

6 METODOLOGIA

Neste capítulo, trata-se da rede neural proposta, abordando as especificidades do problema, o processo de escolha e tratamento dos dados e a arquitetura definida para treinar e avaliar o algoritmo. Na Figura 18 apresenta-se o fluxograma da rede neural proposta.

Figura 18 – Fluxograma da rede



Fonte: Elaborada pelo autor


No desenvolvimento da rede neural, todas as etapas apresentadas pela Figura 18 foram implementadas na linguagem de programação Python, utilizando as bibliotecas *NumPy*, *Pandas* e *scikit-learn* para pré-processamento dos dados de entrada. Posteriormente a biblioteca *TensorFlow* em conjunto com a API *Keras* foram aplicadas para a modelagem, treinamento e avaliação da rede neural.

6.1 Processamento dos dados

Os dados do presente trabalho foram obtidos do Instituto Nacional de Meteorologia (INMET), para as cidades de Itumbiara (estado de Goiás) e Indaial (estado de Santa Catarina). O INMET é um órgão federal administrado pelo Ministério da Agricultura, Pecuária e Abastecimento que tem por missão prover informações meteorológicas no Brasil. O sistema de coleta de dados meteorológicos do INMET é composto por estações de sondagem de ar superior e estações meteorológicas de superfície. Todos os dados obtidos da plataforma são de livre acesso.

Os dados escolhidos são dos anos de 2019 e 2020, contemplando informações hora a hora das seguintes variáveis: pressão, temperatura, umidade, vento e radiação global. Na Figura 19 apresenta-se a correlação entre os dados escolhidos.

Figura 19 – Correlação dos dados

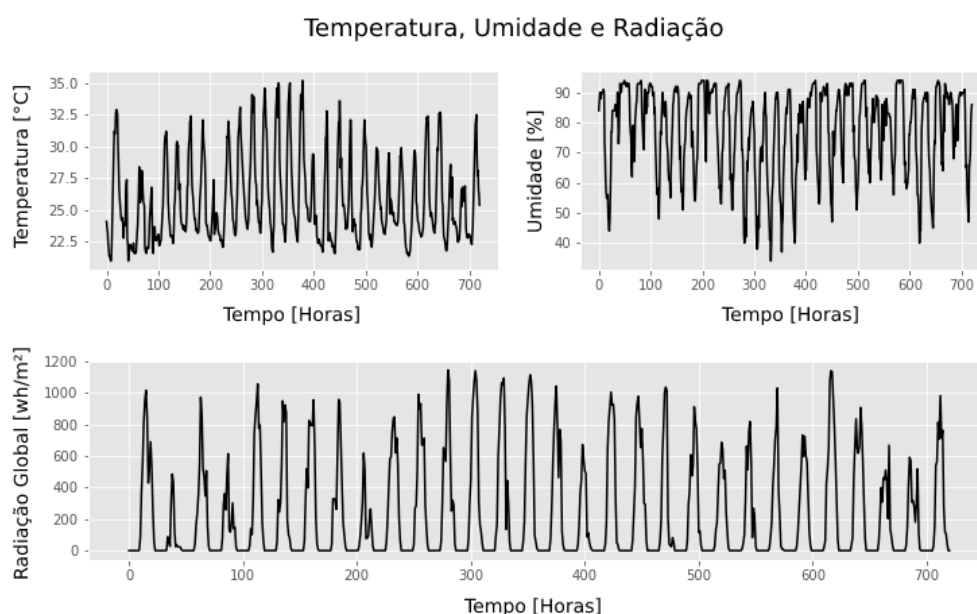


Fonte: Elaborada pelo autor

Para o objetivo do trabalho, atenta-se as correlações da radiação solar global em relação as demais variáveis. Correlações positivas indicam que ambas as variáveis se movem no mesmo sentido e, quanto mais próximo de 1, maior a correlação. Por outro lado, correlações negativas indicam que as variáveis se movem em direções

opostas e quanto mais próximo de menos 1, mais forte é a relação entre ambas. Assim, conclui-se que duas variáveis apresentam pouca correlação com a variável desejada (velocidade do vento e pressão), razão pela qual ambas foram removidas da análise. A Figura 20 apresenta os dados de temperatura, umidade e radiação global para o primeiro mês de 2019.

Figura 20 – Dados meteorológicos em janeiro de 2019



Fonte: INMET (2019)

O tratamento das variáveis selecionadas passou primeiramente pela verificação de falhas. Medições nulas foram preenchidas pela média da leitura anterior e posterior a ocorrência da falha. Assim, os dados passam para a etapa de normalização, sendo limitados ao intervalo $[0, 1]$.

As entradas da rede foram escolhidas de duas formas distintas, sendo a saída igual para ambas. Para o primeiro conjunto de dados (C1), as variáveis de entrada foram temperatura, umidade e radiação solar global, sendo a saída da rede a radiação solar global na hora seguinte. O segundo conjunto de dados (C2) utiliza somente a radiação solar global como variável de entrada.


O conjunto de dados da cidade de Itumbiara possui 17544 medições, das quais 50% foram utilizadas para o treinamento da rede. O restante das amostras foi utilizado nos testes de previsão, em conjunto com as amostras da cidade de Indaiá. Nesse

contexto, justifica-se essa divisão devido as características do problema estudado, sendo que metade dos dados abrange um ano de medições, permitindo que o conjunto de treinamento represente as variações de radiação solar global durante todos os períodos do ano.

6.1.1 Dados para teste

Durante o treinamento e validação da rede neural, foram utilizados os dados apresentados para a cidade de Itumbiara. No entanto, durante os testes da rede neural acrescentaram-se os dados da cidade de Indaial em Santa Catarina. Assim, a rede neural pode ser melhor avaliada quanto a sua generalização, visto que a segunda cidade selecionada possui diferentes condições meteorológicas. Na Figura 21 apresentam-se o comparativo da média diária de energia solar de ondas curtas incidentes para as cidades de Itumbiara e Indaial.

Figura 21 – Média diária de energia solar de ondas curtas em Itumbiara e Indaial



Fonte: Weather Spark (2022)

Para a cidade de Itumbiara, o período mais radiante dura cerca de 3 meses, alcançando uma média diária de 6,0 kWh, sendo setembro o mês mais radiante com 6,2 kWh em média. Por outro lado, o período mais escuro dura cerca de 2 meses, com

uma média diária de 5,1 kWh, sendo junho o mês mais escuro com uma média de 4,8 kWh.

Na cidade de Indaial, o período mais radiante também dura cerca de 3 meses, com uma média diária de 6,1 kWh, sendo dezembro o mês mais radiante com média de 6,8 kWh. Contudo, o período mais escuro dura cerca de 3 meses, com médias de 3,9 kWh, sendo junho o mês mais escuro com uma média de 3,2 kWh.

Assim, foram selecionados os meses de janeiro, abril e julho para testes na cidade de Indaial, objetivando destacar as diferenças de ondas incidentes durante esses meses em relação aos dados de teste de Itumbiara.

6.2 Técnica de Janela

No processo de preparação dos dados, aplicou-se a técnica da janela com período n igual a 12. Assim, a rede neural utiliza amostras de 12 horas anteriores para prever a próxima hora. Nas Figuras 22 e 23 apresenta-se o formato de entrada de dados para os conjuntos de dados C1 e C2, respectivamente.

Figura 22– Entradas e saídas do conjunto C1

Entradas			Saída
Temperatura	Umidade	Radiação	Radiação
$[T_1, T_2, T_3, \dots, T_{12}]$	$[U_1, U_2, U_3, \dots, U_{12}]$	$[R_1, R_2, R_3, \dots, R_{12}]$	$[R_{13}]$
$[T_2, T_3, T_4, \dots, T_{13}]$	$[U_2, U_3, U_4, \dots, U_{13}]$	$[R_2, R_3, R_4, \dots, R_{13}]$	$[R_{14}]$
$[T_3, T_4, T_5, \dots, T_{14}]$	$[U_3, U_4, U_5, \dots, U_{14}]$	$[R_3, R_4, R_5, \dots, R_{14}]$	$[R_{15}]$
\vdots	\vdots	\vdots	\vdots
$[T_{n-12}, T_{n-11}, \dots, X_{n-1}]$	$[U_{n-12}, U_{n-11}, \dots, U_{n-1}]$	$[R_{n-12}, R_{n-11}, \dots, R_{n-1}]$	$[R_n]$

Fonte: Elaborada pelo autor

Figura 23– Entradas e saídas do conjunto C2

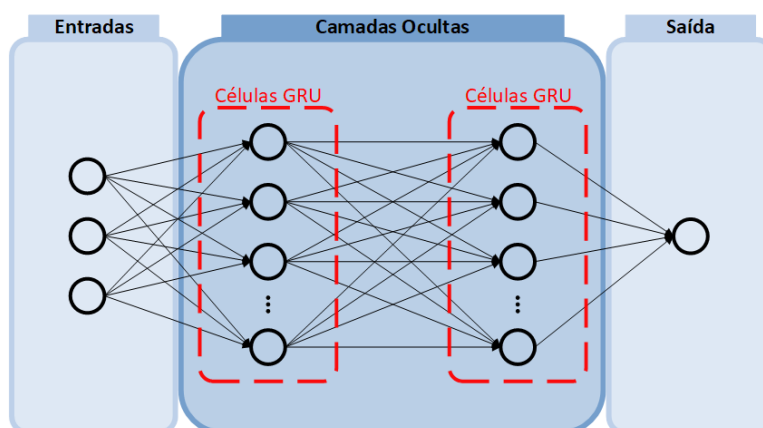
Entradas		Saída
Radiação		Radiação
$[R_1, R_2, R_3, \dots, R_{12}]$	→	$[R_{13}]$
$[R_2, R_3, R_4, \dots, R_{13}]$	→	$[R_{14}]$
$[R_3, R_4, R_5, \dots, R_{14}]$	→	$[R_{15}]$
⋮	⋮	⋮
$[R_{n-12}, R_{n-11}, \dots, R_{n-1}]$	→	$[R_n]$

Fonte: Elaborada pelo autor

6.3 Arquitetura da rede neural recorrente

Neste trabalho, foram desenvolvidas três configurações de redes neurais recorrentes. Ambos os modelos apresentam duas camadas ocultas com função ReLU. A camada de saída apresenta uma célula com função de ativação linear. Para as camadas ocultas, apresentam-se as três configurações desenvolvidas aplicando diferentes células recorrentes, conforme as Figuras 24, 25 e 26.

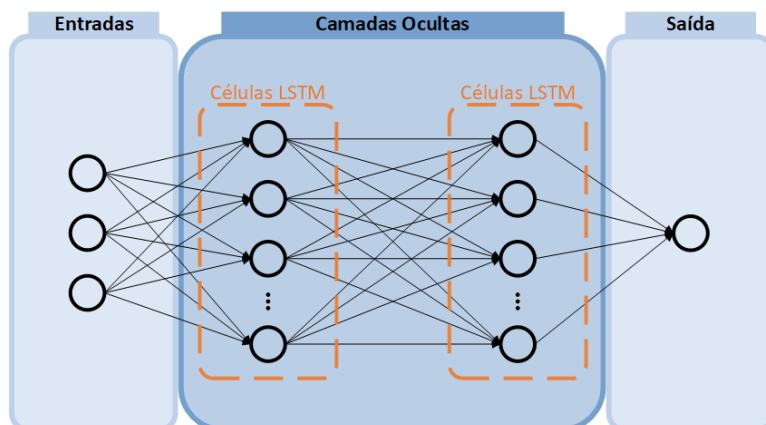
Figura 24 – Rede neural GRU



Fonte: Elaborada pelo autor

Na primeira configuração, ambas as camadas são compostas por células GRU, sendo representada pela Figura 24. Já na segunda configuração, a rede neural possui células LSTM, conforme a Figura 25.


Figura 25 – Rede neural LSTM



Fonte: Elaborada pelo autor

Por fim, a terceira rede foi modelada com uma configuração híbrida, possuindo células LSTM na primeira camada oculta e células GRU na segunda camada oculta, conforme a Figura 26.

Figura 26 – Rede neural híbrida LSTM+GRU



Fonte: Elaborada pelo autor

No treinamento foi implementada a técnica de *early stop* disponível na biblioteca da API Keras, finalizando o processo caso a rede não apresente melhoria após seis épocas consecutivas. Para tal, a métrica utilizada como critério de melhoria para o treinamento foi o erro médio absoluto (MAE).

Ainda, a quantidade de células de cada camada foi decidida através de testes empíricos, observando o coeficiente de determinação (R^2) e tempo de execução. Optou-se por utilizar quantidades iguais para todas as configurações propostas, visando a comparação posterior dos modelos. Isto posto, os parâmetros da rede foram definidos da seguinte forma:

- Número máximo de Épocas = 1000;
- Período = 12;
- *Batch size* = 96;
- Células da camada oculta 1 = 60 e células da camada oculta 2 = 30;
- Algoritmo otimizador Adam;
- Taxa de Aprendizagem = 0,001.

7 RESULTADOS

O processo de treinamento e testes da rede neural proposta foram executados em uma máquina virtual da plataforma Google Colaboratory, possuindo um processador Intel Xeon de dois núcleos de 2.3GHz e 13GB de memória RAM. As três configurações foram treinadas para os dois conjuntos de dados (C1 e C2). Ambas as configurações foram avaliadas segundo as métricas RMSE e R^2 , bem como o tempo de execução. Por fim, o modelo que apresentou os melhores resultados para a cidade de Itumbiara foi testado para a cidade de Indaial.

7.1 Conjunto de dados C1

O primeiro conjunto de dados foi treinado para as três configurações de rede diferentes. Após o treinamento, o modelo realizou previsões com o conjunto de testes. A tabela 1 apresenta os resultados obtidos para ambas as configurações.

Tabela 1 – Resultados para o conjunto C1

Configuração	Métricas de Acurácia		Tempo de Execução (s)
	RMSE	R2	
GRU	62,3852	0,9559	36,55
LSTM	64,9140	0,9507	48,59
Híbrida	66,1124	0,9484	40,79

Fonte: Elaborada pelo autor

Como esperado, a configuração utilizando células GRU apresenta um menor tempo médio de execução. Tal fator se deve a simplificação da célula em relação as células LSTM. Ainda, para o conjunto de dados C1, o modelo apresentou os melhores resultados em relação as métricas de acurácia, alcançando um RMSE de 62,3852 e coeficiente de determinação de 0,9559.

7.2 Conjunto de dados C2

O segundo conjunto de dados, contendo somente a radiação solar global como entrada da rede, foi testado tal qual o conjunto anterior. A tabela 2 apresenta os resultados obtidos para as três configurações.

Tabela 2 – Resultados para o conjunto C2

Configuração	Métricas de Acurácia		Tempo de Execução (s)
	RMSE	R2	
GRU	59,0097	0,9609	28,65
LSTM	58,5305	0,9618	44,05
Híbrida	57,9016	0,9624	41,20

Fonte: Elaborada pelo autor

Novamente, a rede GRU apresentou o menor tempo de execução, com um tempo de execução inferior as demais configurações. Ainda assim, os tempos de execução das demais configurações não se tornam um problema para o objetivo da rede neural de previsão no prazo de uma hora. Logo, a rede híbrida obteve o melhor desempenho geral, com um RMSE de 57,9016 e coeficiente de determinação de 0,9624.

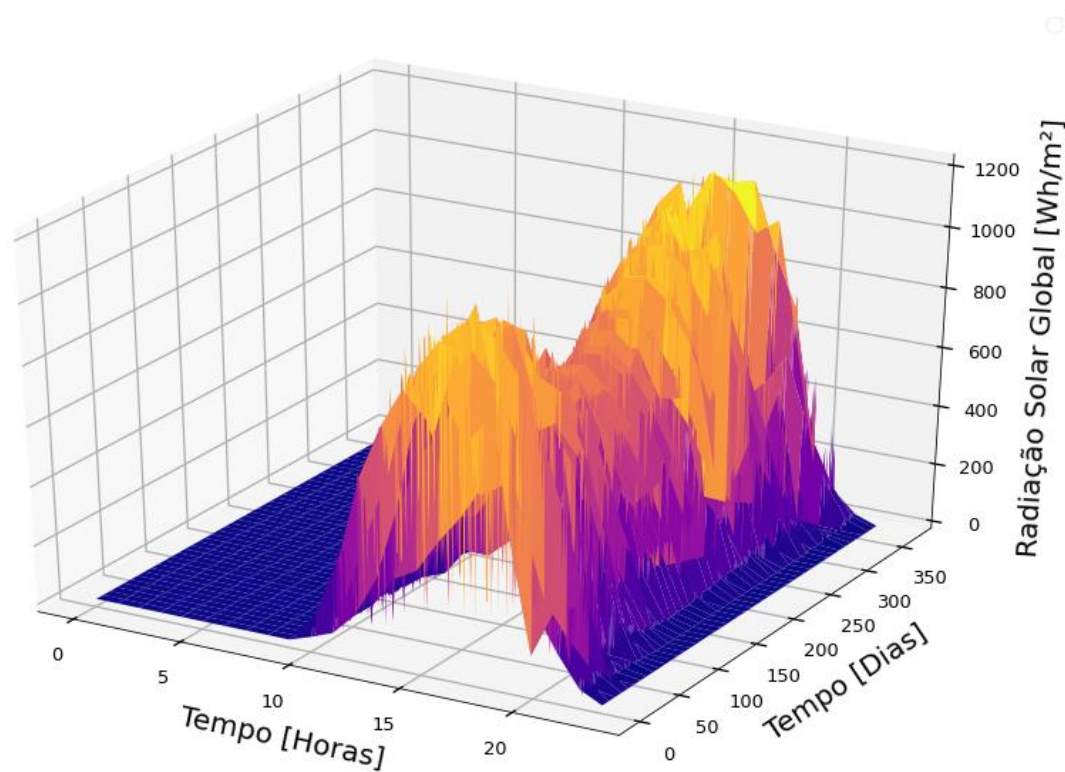
Ainda, o conjunto de dados C2 apresentou melhores resultados em relação ao conjunto C1, razão pela qual a rede híbrida em consonância com o conjunto de dados C2 foi escolhida para dar sequência as análises na seguinte seção.

7.3 Análises da rede neural recorrente proposta

Todos os testes realizados culminaram para a escolha de uma rede neural híbrida contendo células LSTM para a primeira camada oculta e células GRU para a segunda camada oculta. O modelo apresentou os melhores resultados para o conjunto de dados contendo somente a radiação solar global como entrada da rede. Assim, definiu-se a arquitetura e dados para a rede neural recorrente principal que será analisada adiante.

Primeiramente, na Figura 27 apresenta-se os dados de radiação solar global contendo medições do ano de 2019, na cidade de Itumbiara. Isto corresponde a 365 dias de medições hora a hora na estação automática A035 do INMET. Observa-se dos dados que se optou por manter as medições com valor zero, geralmente presentes entre as 23 horas da noite e as 8 horas da manhã do dia seguinte. Alguns testes foram realizados com a remoção desses valores, concluindo-se que a presença dos mesmos não impactou no processo de aprendizado da rede.

Figura 27 – Dados de entrada da rede



Fonte: INMET (2019)

Para a análise da rede foram registradas todas as métricas de acurácia, bem como o coeficiente de determinação. Os resultados obtidos encontram-se na tabela 3.

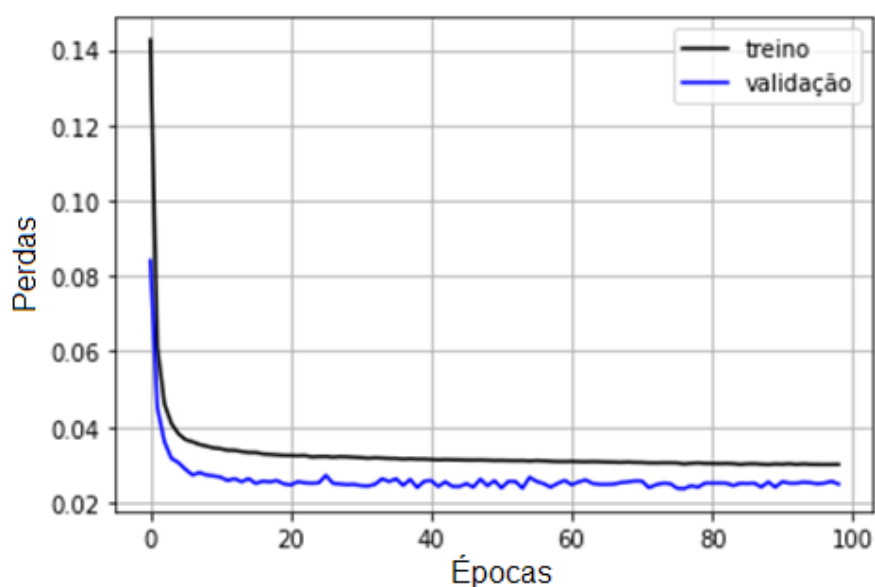
Tabela 3 – Métricas de Acurácia

	Métrica de Acurácia			
	RMSE	MAE	MAPE (%)	R² (%)
Treino	78,9922	36,2861	83,26	-
Teste	55,7798	32,3275	86,22	96,54

Fonte: Elaborada pelo autor.

O modelo híbrido apresentou um erro médio absoluto de 32,3275 Wh/m², com acerto percentual de 86,22% entre as amostras de teste. Destaca-se também o coeficiente de determinação de 96,54%, indicando que as previsões se aproximaram expressivamente dos dados reais. Na Figura 28 apresenta-se a evolução do aprendizado durante o treinamento e validação do modelo.


Figura 28 – Perdas durante o treinamento e validação do modelo



Fonte: Elaborada pelo autor

Ainda, a Figura 29 mostra o gráfico de dispersão do modelo, apresentando a relação entre a radiação solar global obtida pela estação automática do INMET e as previsões da rede neural para o mesmo período de tempo.

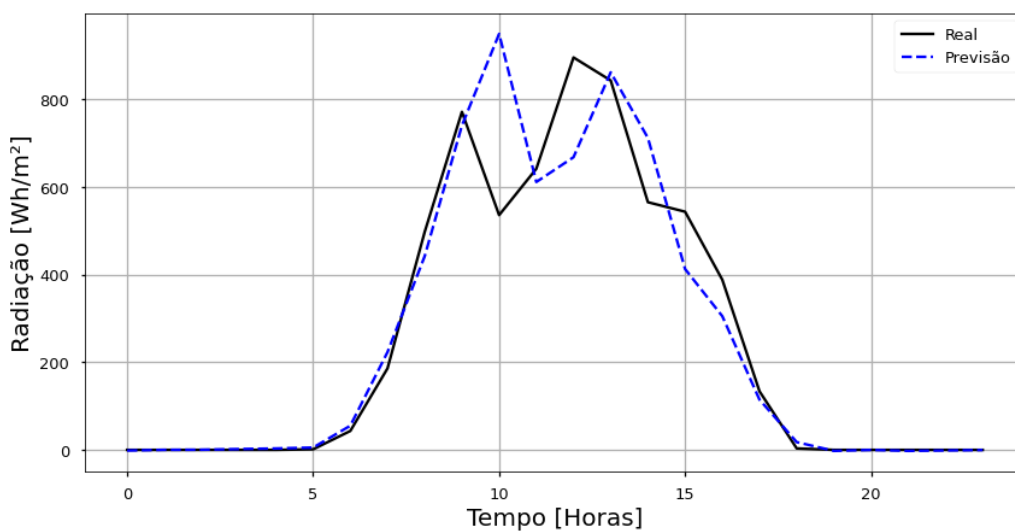
Figura 29 – Gráfico de dispersão



Fonte: Elaborada pelo autor

O gráfico da Figura 30 compara a radiação solar global medida com a prevista durante um período de 24 horas. Posteriormente o gráfico da Figura 31 apresenta uma previsão ao longo de 24 horas após 72 horas de medição.

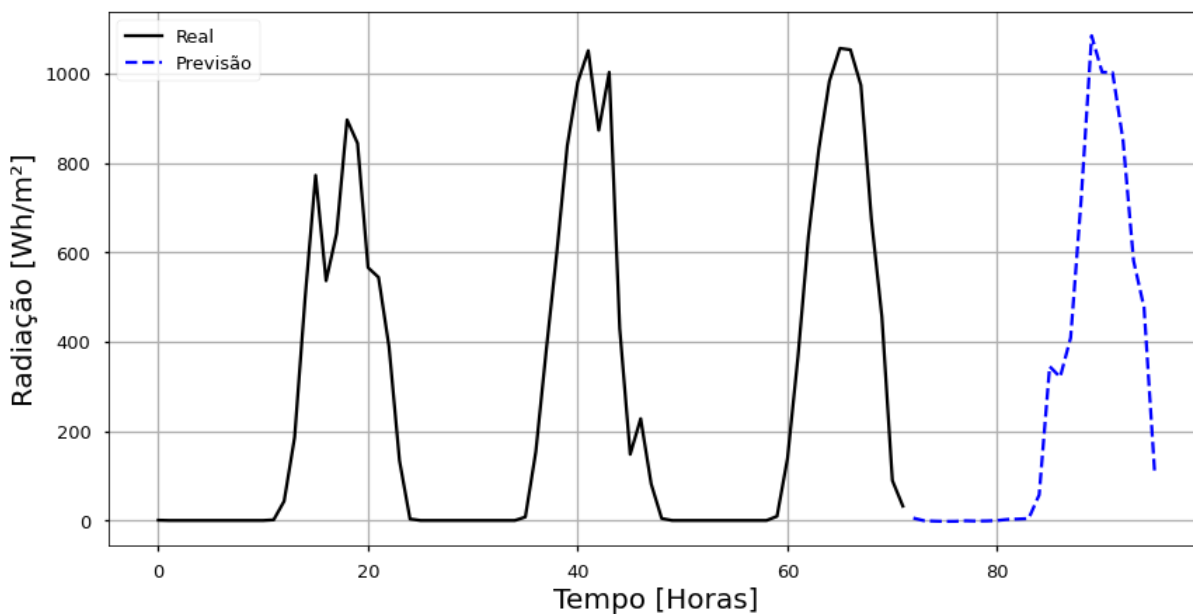
Figura 30 – Comparação entre medição e previsão de radiação global



Fonte: Elaborada pelo autor

O valor medido da radiação para o dia escolhido para testes na Figura 30 foi de 6,05 kWh/m² enquanto o valor previsto foi de 6,12 kWh/m². Nesse cenário, o valor real correspondeu a 98,89% da previsão para o dia analisado.


Figura 31 – Previsão da radiação global ao longo de 24 horas



Fonte: Elaborada pelo autor

Assim, após os testes iniciais, foram realizadas as previsões para os meses de janeiro, abril e julho na cidade de Itumbiara. Na Figura 32, apresenta-se as previsões de radiação solar global para quatro dias durante o mês de janeiro.


Figura 32 – Previsões em janeiro na cidade de Itumbiara



Fonte: Elaborada pelo autor

A seguir, na Figura 33 apresenta-se os resultados obtidos para quatro dias distintos durante o mês de abril.


Figura 33 – Previsões em abril na cidade de Itumbiara



Fonte: Elaborada pelo autor

Por fim, na Figura 34 apresenta-se os resultados de previsão para quatro dias distintos durante o mês de julho. Em seguida, a tabela 4 apresenta os resultados para os meses analisados.

Figura 34 – Previsões em julho na cidade de Itumbiara



Fonte: Elaborada pelo autor

Tabela 4 – Resultados para a cidade de Itumbiara


Mês de Referência	Métricas de Acurácia	
	RMSE	R2
Janeiro	98,9629	0,9250
Abril	90,8551	0,9159
Julho	55,7285	0,9600

Fonte: Elaborada pelo autor

7.3.1 Análise na cidade de Indaial

Após a análise na cidade de Itumbiara, escolhida para o treinamento da rede neural recorrente, algumas previsões foram realizadas para a cidade de Indaial no estado de Santa Catarina. Na Figura 35 apresenta-se as previsões em quatro dias aleatórios do mês de janeiro.


Figura 35 – Previsões em janeiro na cidade de Indaial



Fonte: Elaborada pelo autor

A seguir, na Figura 36 apresenta-se as previsões para o mês de abril.


Figura 36 – Previsões em abril na cidade de Indaial



Fonte: Elaborada pelo autor

Por fim, na Figura 37 apresenta-se os resultados de previsões em quatro dias diferentes durante o mês de julho.

Figura 37 – Previsões em julho na cidade de Indaial



Fonte: Elaborada pelo autor

Ainda, na tabela 5, apresenta-se os resultados para ambos os testes, conforme as métricas de acurácia estabelecidas para avaliação da rede.

Tabela 5 – Resultados para a cidade de Indaial

Mês de Referência	Métricas de Acurácia	
	RMSE	R2
Janeiro	95,7233	0,8955
Abril	55,7318	0,9454
Julho	56,1830	0,9080

Fonte: Elaborada pelo autor

Durante o mês de janeiro, existe uma variação maior da radiação solar global durante as horas do dia. Tal fator impactou diretamente nas previsões para o mês em questão, que obteve as piores métricas entre todos os testes realizados.

8 CONCLUSÕES

A proposta deste trabalho concentra-se no desenvolvimento de uma rede neural recorrente para previsão de radiação solar global com horizonte de uma hora. Na elaboração da proposta, buscou-se desenvolver uma metodologia robusta para previsão tratando-se de problemas não lineares.

A metodologia consistiu no desenvolvimento e comparação de três diferentes configurações de arquitetura, sendo elas a rede GRU, rede LSTM e rede híbrida. Ainda, adotou-se dois conjuntos de dados diferentes. Durante o processo de treinamento da rede e teste na cidade de Itumbiara, o modelo híbrido foi o que apresentou melhores métricas de acurácia, com um tempo de execução médio em relação as demais configurações. Para a entrada da rede, o conjunto contendo somente a radiação solar global obteve o melhor apuramento, resultando na escolha da rede recorrente neural híbrida com variável de entrada única. Os gráficos expostos apresentaram resultados satisfatórios para o modelo final proposto.

Contudo, vale ressaltar que nas análises adicionais para a cidade de Indaial, a rede neural, quando exposta a dados com maiores variações hora a hora como o mês de janeiro, apresentou dificuldades na previsão. Tal fator indica a importância da escolha dos dados para o treinamento de redes neurais, visando generalizar o modelo para diferentes situações. Todavia, por apresentar variações significativas entre as regiões estudadas, indica-se a possibilidade de treinamentos individuais que proporcionem diferentes modelos treinados que se apliquem conforme a região. Nesse sentido, modelos treinados regionalmente podem alcançar uma maior eficácia em relação a um único modelo generalizado.

Ainda assim, deve-se atentar a problemática da nebulosidade, que apresenta característica extremamente local, dificultando a previsão em meses com presença maior de nuvens. Nesse sentido, ainda que de forma geral a rede neural proposta consiga prever de forma satisfatória a radiação solar global ao longo do ano, continuará apresentado erros maiores em casos como o mês de janeiro.

Diante do que foi apresentado, pondera-se a importância da aplicação de metodologias de inteligência artificial no acompanhamento da evolução do sistema elétrico de potência, que se torna cada vez mais complexo. Tais ferramentas ainda são relativamente novas e estudos na área tendem a aprimorar e reforçar a inserção

de tais metodologias nas chamadas redes inteligentes. Com o acesso cada vez maior de grandes volumes de dados, o futuro tende progressivamente ao aprimoramento de técnicas sofisticadas de inteligência artificial nos diversos âmbitos da sociedade, não excluindo-se o setor elétrico.

Por fim, conclui-se que os objetivos propostos para o presente trabalho foram alcançados. Os resultados expostos mostraram a capacidade das redes neurais artificiais na previsão de problemas não lineares, alcançando resultados significativos nas previsões para ambos os modelos desenvolvidos.

8.1 Propostas de trabalhos futuros

Ainda que a metodologia abordada tenha apresentado resultados positivos, este trabalho trata apenas de poucas entre as várias possibilidades presentes em redes neurais artificiais. Desde a definição dos hiperparâmetros até a escolha dos dados que alimentam a rede, evidencia-se algumas alternativas de desenvolvimento futuro:

- Abordar diferentes arquiteturas de redes neurais recorrentes para previsão da radiação solar global, comparando os resultados obtidos;
- Realizar a previsão da geração solar fotovoltaica utilizando o modelo proposto, verificando o impacto das demais variáveis meteorológicas;
- Utilizar diferentes conjuntos de dados para verificar a robustez dos modelos de previsão;
- Aprimorar a rede com técnicas (desde o tratamento dos dados até a definição de arquitetura da rede) que melhor generalizem o modelo.

REFERÊNCIAS

ABDEL-NASSER, M.; MAHMOUD, K. **Accurate photovoltaic power forecasting models using deep lstm-rnn**. *Neural Computing and Applications*, v. 31, 2017.

ABEDIN, Z.; BARUA, M.; PAUL, S.; AKTHER, S.; CHOWDHURY, R.; CHOWDHURY, M. H. **A model for prediction of monthly solar radiation of different meteorological locations of Bangladesh using artificial neural network data mining tool**. 2017. Disponível em: <https://ieeexplore.ieee.org/document/7912993> . Acesso em: 10 ago. 2022.

ABSOLAR. **Brasil bate recordes no setor de energia solar: 1 milhão de consumidores com geração própria e 21,8 bilhões de investimentos em 2021**. Disponível em: <https://www.absolar.org.br/noticia/brasil-bate-recordes-no-setor-de-energia-solar-1-milhao-de-consumidores-com-geracao-propria-e-218-bilhoes-de-investimentos-em-2021/>. Acesso em: 19 mai. 2022.

ABSOLAR. **Energia Solar Fotovoltaica no Brasil**: Infográfico ABSOLAR nº 39. Disponível em: <https://www.absolar.org.br/wp-content/uploads/2022/01/2022.01.11-Infografico-ABSOLAR-n%C2%B0-39.pdf>. Acesso em: 25 mai. 2022

ANDRADE, L. C. **Abordagem Neurofuzzy Para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. 2010. 147f. Dissertação (Mestrado em Engenharia) – Universidade de São Paulo, São Carlos, 2010.

ANEEL/ABSOLAR. **Fonte solar fotovoltaica assume 7ª posição na matriz elétrica brasileira e ultrapassa nucleares**. 2019.

BALFOUR, J; SHAW, M; NASH, N. B. **Introdução ao projeto de sistemas fotovoltaicos**. 1. Ed. São Paulo: GEN LTC, 2016.

BARRETO, R. G; MARINHO, G. M. G. A.; BARRETO, G. F. M.; BARRETO, R. G.; AVERSARI, L. O. C.; DANTAS, B. L. Utilizando Redes Neurais Artificiais para o Diagnóstico de Câncer Cervical. **Revista Saúde e Ciência**, v. 7, n. 2, 2018.

BARROS, B. F; GEDRA, R. L.; BORELLI, R. **Gerenciamento de energia**: ações administrativas e técnicas de uso adequado da energia elétrica. 2. Ed. São Paulo: Érica, 2015.

BROWNLEE, J. **Difference Between a Batch and an Epoch in a Neural Network**. Disponível em: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>. Acesso em: 29 nov. 2021.

CAMPOS, C. **Curso básico de direito de energia elétrica**. 1. Ed. São Paulo: Synergia, 2010.

HEIN, H. **Sete estados brasileiros já contam com energia solar em 100% dos municípios**. CANAL SOLAR, 2021. Disponível em: <https://canalsolar.com.br/sete->

estados-brasileiros-ja-contam-com-energia-solar-em-100-dos-municipios/. Acesso em: 19 mai. 2022.

CECCON, D. **Funções de ativação**: definição, características, e quando usar cada uma. Disponível em: <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/>. Acesso em: 30 nov. 2021.

COUTINHO, A. C.; SILVA, R. M.; DELGADO, A. R. S. **Utilização de Técnicas de Inteligência Computacional na Predição de Dados Meteorológicos**. Revista Brasileira de Meteorologia, v. 31, n. 1, 2016.

CREDER, H. **Instalações Elétricas**. 17. Ed. São Paulo: Gen LTC, 2021.

DATA SCIENCE ACADEMY. **Arquitetura de Redes Neurais Long Short Term Memory (LSTM), 2022**. Disponível em: <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-long-short-term-memory/>. Acesso em: 06 jan. 2022.

DATA SCIENCE ACADEMY. **Matemática na GRU, Dissipação e Clipping do Gradiente, 2022**. Disponível em: <https://www.deeplearningbook.com.br/matematica-na-gru-dissipacao-e-clipping-do-gradiente/>. Acesso em: 06 jan. 2022.

DATA SCIENCE ACADEMY. **O Efeito do Batch Size no Treinamento de Redes Neurais Artificiais, 2022**. Disponível em: <https://www.deeplearningbook.com.br/o-efeito-do-batch-size-no-treinamento-de-redes-neurais-artificiais/>. Acesso em: 13 abr. 2022.

DIDÁTICA TECH. **A biblioteca scikit-learn – Python: o que é, para que serve**. Disponível em: <https://didatica.tech/a-biblioteca-scikit-learn-pyhton-para-machine-learning/>. Acesso em: 30 ago. 2022.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Projetos fotovoltaicos nos leilões de energia**. 2020.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Balanco Energético Nacional**. 2022.

FIOROTTI, A. **Mercado Atacadista de Energia Elétrica**. São Paulo: Synergia, 2019.

FREITAS, A. G. S.; FERREIRA, P. M.; SILVA, R. M. **Redes Neurais na Classificação de Neoplasias Mamárias**. Revista Cereus, v. 11, n. 1, 2019.

GANIM, A. **Setor Elétrico Brasileiro**. 1. Ed. São Paulo: Synergia, 2019.

GERON, A. **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: Conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. 2. Ed. São Paulo: Atlas, 2021.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. Ed. São Paulo: Bookman, 2000.

HINTON, G.; SRIVASTAVA, N.; SWERSKY, K. **Neural networks for machine learning lecture 6a overview of minibatch gradient descent**. Disponível em: http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf. Acesso em: 07 jan. 2022.

HIRANSHA, M.; GOPALAKRISHNAN, E. A.; MENON, V. K.; SOMAN, K.P. **NSE stock market prediction using deep-learning models**. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050918307828>. Acesso em: 05 jan. 2022.

HOPFIELD, J. J. **Neural Networks and Physical Systems with Emergent Collective Computational Abilities**. In: PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF THE UNITED STATES OF AMERICA, 79., 1982, Los Angeles. Anais... PNASUSA: Los Angeles, 1982.

INMET. **Tabela de Dados das Estações**. Disponível em: <https://tempo.inmet.gov.br/TabelaEstacoes/>. Acesso em: 30 ago. 2022.

KALOGIROU, S. **Engenharia de energia solar: Processos e Sistemas**. São Paulo: GEN LTC, 2016.

KINGMA, D. P.; BA, J. **Adam: A Method for Stochastic Optimization**. arXiv e-prints, p. arXiv:1412.6980, dez. 2014.

KRISHNAIAH, T. E., RAO, S. S.; MADHUMURTHY, K.; REDDY, K. S. **Neural Network Approach for Modelling Global Solar Radiation**. Journal of Applied Sciences Research, v. 3, n. 10, 2007.

LIMA, A. H. N.; LACERDA, W. S.; NETO, H. S. **Seleção de características de dados utilizando Redes Neurais Artificiais**. In: XIII Brazilian Symposium on Information Systems, Lavras, 2017.

LIMA, J. L. B. **Energia fotovoltaica como alternativa energética viável**. 1. ed. São Paulo: Érica, 2014.

LOPES, J. H. O. **Previsão de produção fotovoltaica a muito curto prazo usando análise e modelação de dinâmica de sombras**. Dissertação (Mestrado em Engenharia) – Universidade do Porto, Porto, 2010.

LOUREIRO, G. K.; DIAS, F. H. D. L.; SENA, B. B.; RAMALHO, E. E. F.; SOUZA, L. F. F. **Manual De Direito Da Energia Elétrica**. 1. Ed. São Paulo: Quartier Latin, 2021.

MACHADO, C. T.; MIRANDA, F. S. **Energia Solar Fotovoltaica: Uma Breve Revisão**. Revista de Química, v. 7, n. 1, 2015.

MAMEDE FILHO, J. **Subestações de Alta Tensão**. 1. Ed. São Paulo: LTC, 2021.

MARTINS, E. R.; BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. **Configuração de Redes Neurais Artificiais para Estimação do Afilamento do Fuste de Árvores de Eucalipto**. Agrária, v. 11, n. 1, 2016.

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

MELLIT, A.; MENGHANEM, M.; BENDEKHIS, M. **Artificial Neural Network Model for Prediction Solar Radiation Data**: Application for Sizing Stand-alone Photovoltaic Power System. IEEE Power Engineering Society, v. 7, 2005.

MENDES, I. A.; REZENDE, R. A. D.; NASCIMENTO, T. H. F.; SILVA, J. S. F.; SILVA, O. F. **A Utilização das Redes Neurais Artificiais na Previsão de Radiação Solar Global**. In: CONGRESSO TÉCNICO CIENTÍFICO DA ENGENHARIA E DA AGRONOMIA, 7., 2017, Belém. Anais... CTCEA: Belém, 2017.

MINSKY, M.; PAPERT, S. **Perceptrons**: An Introduction to Computational Geometry. Massachusetts: MIT Press, 1969.

MINUSSI, C. R. **Redes neurais**: Introdução e Principais Conceitos. Universidade Estadual Paulista (UNESP), São Paulo, 2008.

MOREIRA, E. R. S. **Energias Renováveis, Geração Distribuída e Eficiência Energética**. 1. Ed. São Paulo: GEN LTC, 2017.

MURPHY, K. P. **Machine Learning**: A probabilistic Perspective. Reino Unido: MIT Press, 2012.

NAIR, V.; HINTON, G.E. **Rectified Linear Units Improve Restricted Boltzmann Machines**. Universidade de Toronto, Canadá, 2010.

NWANKPA, C.E.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. **Activation Functions**: Comparison of Trends in Practice and Research for Deep Learning. arXiv e-prints, p. arXiv:1811.03378, nov. 2018.

OLIVEIRA, A.; SALOMAO, L. A. **Setor elétrico brasileiro**: Estado e mercado. 1. Ed. São Paulo: Synergia, 2017.

PANDAS. **About Pandas**. Disponível em: <https://pandas.pydata.org/about/index.html>. Acesso em: 30 ago. 2022.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, P.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. **Scikit-learn**: Machine Learning in Python. Disponível em: <https://jmlr.csail.mit.edu/papers/volume12/pedregosa11a/pedregosa11a.pdf>. Acesso em: 30 ago. 2022.

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. 80p.
Disponível em: <http://doi.org/10.34024/978851700089>

REIS, L. B. **Geração de energia elétrica**. 3. Ed. São Paulo: Manole, 2017.

RODRIGUES, J. F. S.; RICARDO, J. C. S.; SANTOS, M. R. **Energia Fotovoltaica: uma opção para a eletrificação de áreas rurais isoladas**. 1. Ed. São Paulo: Érica, 2013.

ROSA, A. **Processos de energia renováveis**. 1. Ed. São Paulo: GEN LTC, 2014.

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

RUDER, S. **An overview of gradient descent optimization algorithms**. arXiv e-prints, p. arXiv:1609.04747, set. 2016.

RUMELHART, D. E.; MCCLELLAND, J.L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. Cambridge: MIT Press, 1986.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning Representations by Backpropagation Errors**. *Nature*, v. 323, 1986.

RUSSELL, S.; NORVIG, P. P. **Inteligência Artificial**. 3. Ed. São Paulo: Gen, 2013.

RUTTER, R.; PINTO, G. X. A.; NASPOLINI, H. F. **Impactos Da Agregação Da Energia Solar Fotovoltaica Sobre As Despesas Com Energia Elétrica**. 1. Ed. São Paulo: Appris, 2019.

SA, A. F. R. **Guia de Aplicações de Gestão de Energia e Eficiência Energética**. 3. Ed. São Paulo: Publindústria, 2010.

SANTOS, O. A. B. **Previsão de Produção de Centrais Solares a Muito Curto Prazo**. 2010. 74f. Dissertação (Mestrado em Engenharia) – Universidade do Porto, Porto, 2010.

SEJNOWSKI, T. J. **A revolução do aprendizado profundo**. 1. Ed. São Paulo: Atlas, 2020.

SILVA, E. A. **Técnicas de estimação de parâmetros de módulos fotovoltaicos**. 2015. 117 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco, Recife, 2015.

SILVA, I. N. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos**. 2. Ed. São Paulo: Artliber, 2016.

SOARES, J.; OLIVEIRA, A. P.; BOZNAR, M. Z.; MLAKAR, P.; ESCOBEDO, J. F.; MACHADO, A. J. **Modeling hourly diffuse solar radiation in the city of São Paulo using neural network technique**. *Applied Energy*, v. 79, 2004.

SOUZA, A. C. Z.; BONATTO, B. D.; RIBEIRO, P. F. **Integração de Renováveis e Redes Elétricas Inteligentes**. 1. Ed. São Paulo: Interciência, 2020.

SU, D.; BATZELIS, E.; PAL, B. **Machine learning algorithms in forecasting of photovoltaic power generation**. IEEE, 2019.

TAQI, A. M.; AWAD, A.; AL-AZZO, F.; MILANOVA, N. **The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance**. In: 2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR), 2018.

WEATHER SPARK. **Compare o clima e as condições meteorológicas de Indaial e Itumbiara**. Disponível em: <https://pt.weatherspark.com/compare/y/29899~29959/Compara%C3%A7%C3%A3o-das-caracter%C3%ADsticas-meteorol%C3%B3gicas-m%C3%A9dias-em-Indaial-e-Itumbiara#Figures-Temperature>. Acesso em: 25 mai. 2022.

WIDROW, B.; HOFF, M. B. **Adaptive switching circuits**. In: IRE WESCON CONVENTION RECORD, 1, Los Angeles, 1960. Anais... IRE: Los Angeles, 1960.

WIKIPEDIA CONTRIBUTORS. **Long Short-Term Memory**. Disponível em: https://commons.wikimedia.org/wiki/File:Long_Short-Term_Memory.svg. Acesso em: 19 dez. 2021.

ZAREMBA, W.; SUTSKEVER, I.; VINYALS, O. **Recurrent Neural Network Regularization**. arXiv e-prints, p. arXiv:1409.2329, set. 2014.

ANEXOS

ANEXO A – CONJUNTO DE DADOS

Link de acesso para os dados utilizados no presente trabalho:

<https://drive.google.com/drive/folders/185KerbmamynsuEUr0v0dxsXKfZ-f0AU?usp=sharing>