

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO ENGENHARIA ELÉTRICA E ELETRÔNICA

André Furlaneti de Melo

Aplicação de Algoritmos de Aprendizado de Máquinas na Estimativa da Irradiação Solar para
Geração Fotovoltaica: Um Estudo de Caso

Florianópolis

2023

André Furlaneti de Melo

Aplicação de Algoritmos de Aprendizado de Máquinas na Estimativa da Irradiação Solar para
Geração Fotovoltaica: Um Estudo de Caso

Trabalho de Conclusão de Curso submetido ao curso de Graduação em Engenharia Elétrica do Centro de Tecnológico da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Me. Eng. André Felipe Vitorio Sprotte

Florianópolis

2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Melo, André Furlaneti de
Aplicação de algoritmos de aprendizado de máquinas na
estimativa da irradiação solar para geração fotovoltaica: um
estudo de caso / André Furlaneti de Melo ; orientador,
André Felipe Vitorio Sprotte, 2023.
53 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Aprendizado de máquinas. 3.
Irradiação global solar. 4. Energia elétrica fotovoltaica.
5. Redes neurais. I. Sprotte, André Felipe Vitorio. II.
Universidade Federal de Santa Catarina. Graduação em
Engenharia Elétrica. III. Título.

André Furlaneti de Melo

**APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINAS NA
ESTIMATIVA DA IRRADIAÇÃO SOLAR PARA GERAÇÃO FOTOVOLTAICA:
UM ESTUDO DE CASO**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia Elétrica” e aceito, em sua forma final, pelo Curso de Graduação em Engenharia Elétrica.

Florianópolis, 11 de julho de 2023.



Documento assinado digitalmente

Miguel Moreto

Data: 11/07/2023 20:06:54-0300

CPF: ***.850.100-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Miguel Moreto, Dr.
Coordenador do Curso de Graduação em Engenharia Elétrica

Banca Examinadora:



Documento assinado digitalmente

ANDRÉ FELIPE VITORIO SPROTTE

Data: 11/07/2023 19:33:06-0300

CPF: ***.576.049-**

Verifique as assinaturas em <https://v.ufsc.br>

Eng^o. Eletric. André Felipe Vitorio Sprotte, Me.
Orientador
Universidade Federal de Santa Catarina



Documento assinado digitalmente

Luis Otavio Steffenmunsberg Grillo

Data: 11/07/2023 19:33:38-0300

CPF: ***.860.500-**

Verifique as assinaturas em <https://v.ufsc.br>

Prof. Luis Otavio Steffenmunsberg Grillo, Me.
Universidade Federal de Santa Catarina



Documento assinado digitalmente

VANDERLEIA CONTINI FERRAZ

Data: 11/07/2023 19:34:01-0300

CPF: ***.611.219-**

Verifique as assinaturas em <https://v.ufsc.br>

Eng^a. Eletric. Vanderleia Contini Ferraz.
Risen Energy Co. Ltd.

Este trabalho é dedicado aos meus pais, que sempre me apoiaram,
e aos meus amigos que estiveram comigo nesta jornada.

AGRADECIMENTOS

Agradeço aos meus pais por todo o apoio, compreensão e conselhos ao longo da graduação e da vida.

Aos professores e professoras do Departamento de Engenharia Elétrica e Eletrônica que procuram dar excelentes aulas e se preocupam com cada um dos alunos que compõem a turma. Têm a minha admiração.

Ao Hiago Antonio Sirino Danguì pelo aceite na equipe do Laboratório de Metrologia e Automatização em que pude desenvolver características como disciplina, curiosidade e dedicação para assim desenvolver por ao longo de um ano a pesquisa e publicá-la.

Ao André Felipe Vitorio Sprotte por orientar e ajudar nos momentos de dúvidas e dificuldades, sempre disponível quando necessário.

RESUMO

Este trabalho de conclusão de curso tem como objetivo estudar a possibilidade de utilizar algoritmos de aprendizado de máquina para prever a irradiação global solar e, assim, utilizá-los em aplicações na área de energia elétrica fotovoltaica. Os dados meteorológicos utilizados no trabalho foram obtidos pela NASA e os dados de geração de energia solar fotovoltaica de uma usina de 2,5 MWp foram fornecidos por uma pessoa jurídica de direito privado, ambos os dados são da cidade de Campinas - São Paulo. Os dados foram tratados e analisados os seus comportamentos característicos e a sua integridade através do mapa de correlação de Pearson e gráficos *boxplot*. Assim, a variável “ALLSKY_SFC_SW_DWN” foi escolhida como alvo para os algoritmos preverem o seu comportamento e, a partir dessa escolha, as variáveis que apresentaram maior correlação foram a temperatura e a velocidade do vento. Neste trabalho, foi utilizado o método de *Extreme Gradient Boost* para entender a convergência do treinamento e a validação com um método que é simples e robusto. Partindo desse resultado, foram aplicados os métodos de *Long Short-Term Memory* (LSTM), Redes Neurais Convolucionais (RNC) e *Multilayer Perceptron*. Os resultados obtidos atingiram o objetivo proposto e o método com melhor desempenho foi o RNC e LSTM juntos.

Palavras-chave: Aprendizado de máquinas, Irradiação global solar, Energia elétrica fotovoltaica, Redes neurais.

ABSTRACT

The objective of this work is to investigate the feasibility of using machine learning algorithms to predict global solar irradiation, with potential applications in the field of photovoltaic electricity generation. The meteorological data used in this study were obtained from NASA, while the solar power generation data from a 2.5 MWp plant were provided by a private entity. Both datasets pertain to Campinas, São Paulo. The data underwent preprocessing and analysis to assess their characteristic behavior and integrity using Pearson correlation maps and box plots. Subsequently, the target variable "ALLSKY_SFC_SW_DWN" was selected for neural network prediction, with temperature and wind speed showing the highest correlations. The Extreme Gradient Boost method was employed to understand the convergence of training and validation, as it is a simple and robust approach. Based on these findings, Long Short-Term Memory (LSTM), Convolutional Neural Network (CNN), and Multilayer Perceptron methods were applied. The results achieved the proposed objective, with the CNN and LSTM combined method demonstrating the best performance.

Keywords: Machine learning, Global solar irradiation, Photovoltaic electricity generation, Neural network.

LISTA DE FIGURAS

Figura 1 - Espectro da composição da irradiância solar.....	4
Figura 2 - Camadas que compõem um módulo fotovoltaico monocristalino Si.....	5
Figura 3 - Natureza da irradiação solar.....	6
Figura 4 - Balanço energético da Terra.....	6
Figura 5 - Atlas global de irradiação global horizontal.....	7
Figura 6 - Total diário da irradiação global horizontal média anual.....	9
Figura 7 - Efeito fotovoltaico na junção <i>pn</i>	10
Figura 8 - Porcentagem da produção global anual de módulos fotovoltaicos.....	11
Figura 9 - Porcentagem da produção global anual de módulos fotovoltaicos <i>thin film</i>	12
Figura 10 - Eficiência de células e módulos fotovoltaicos testados em laboratório. .	13
Figura 11 - Especificação dos algoritmos de inteligência artificial.....	14
Figura 12 - Representação do modelo Perceptron.....	17
Figura 13 - Especificação do algoritmo LSTM.....	18
Figura 14 - Exemplo da aplicação da convolução para a criação da <i>hidden layer</i>	22
Figura 15 - Exemplo da aplicação da <i>feature max-pooling</i>	23
Figura 16 - Exemplo da rede neural <i>MLP</i>	24
Figura 17 - Irradiação solar x geração de energia fotovoltaica da Usina 01.....	27
Figura 18 - Matriz de correlação de Pearson das variáveis meteorológicas.....	34
Figura 19 - <i>Boxplot</i> “ <i>ALLSKY_SFC_SW_DWN</i> ”.....	35
Figura 20 - <i>Boxplot</i> “ <i>T2M</i> ”.....	36
Figura 21 - <i>Boxplot</i> “ <i>T2MWET</i> ”.....	36
Figura 22 - <i>Boxplot</i> “ <i>WD10M</i> ”.....	37
Figura 23 - Etapa vs RMSE treino e validação <i>XGBoost</i>	38
Figura 24 - Época vs RMSE treino e validação LSTM.....	39
Figura 25 - Época vs <i>Loss</i> treino e validação LSTM.....	40
Figura 26 - Época X RMSE treino e validação <i>Stacked LSTM</i>	41
Figura 27 - Época X <i>Loss</i> treino e validação <i>Stacked LSTM</i>	42
Figura 28 - Época X RMSE treino e validação RNC.....	43
Figura 29 - Época X <i>Loss</i> treino e validação RNC.....	44
Figura 30 - Época X RMSE treino e validação RNC e LSTM.....	45
Figura 31- Época X <i>Loss</i> treino e validação RNC e LSTM.....	45

Figura 32 - Época X RMSE treino e validação MLP.....	46
Figura 33 - Época X <i>Loss</i> treino e validação MLP.	46
Figura 34- Previsão da irradiação “ALLSKY_SFC_SW_DWN” por cada modelo..	48
Figura 35- Densidade de nuvens no céu dia 18/10/2021.....	49
Figura 36 - Densidade de nuvens no céu dia 22/10/2021.....	49

LISTA DE QUADROS

Quadro 1 – Dados meteorológicos.....	25
Quadro 2 – Parâmetros utilizados no <i>XGBoost</i>	29
Quadro 3 – Parâmetros LSTM.....	30
Quadro 4 – Parâmetros <i>Stacked</i> LSTM.....	31
Quadro 5 – Parâmetros RNC.....	32
Quadro 6 – Parâmetros MLP.....	33

LISTA DE TABELAS

Tabela 1 – RMSE e <i>Loss</i> de treino cada modelo de rede neural.....	47
Tabela 2 – RMSE e <i>Loss</i> de validação cada modelo de rede neural.....	47

LISTA DE ABREVIATURAS E SIGLAS

CdTe - Telureto de cádmio

CIGS - Cobre Índio Gálio Selênio

LSTM - *Long Short-Term Memory*

MLP - *Multilayer Perceptron*

MSE - *Mean Square Error*

RMSE - *Root Mean Square Error*

RNC - Rede Neural Convolutacional

RNN - *Recurrent Neural Network*

SI - Sistema Internacional

Si - Silício

TCC - Trabalho de Conclusão de Curso

XGBoost - eXtreme Gradient Boost

SUMÁRIO

1	INTRODUÇÃO E CONTEXTUALIZAÇÃO	1
1.1	JUSTIFICATIVA	2
1.2	OBJETIVOS	2
1.3	ROTEIRO	3
2	REVISÃO BIBLIOGRÁFICA	4
2.1	ENERGIA SOLAR.....	4
2.1.1	Irradiação solar.....	5
2.1.2	Efeitos geográficos e meteorológicos.....	7
2.1.3	Evolução tecnológicas dos módulos.....	9
2.2	algoritmos de aprendizado de máquinas.....	13
2.2.1	Redes Neurais.....	15
2.2.2	Alguns algoritmos conceituados	17
3	PROCEDIMENTOS METODOLÓGICOS.....	25
3.1	BANCO DE DADOS	25
3.2	TRATAMENTO DOS DADOS METEOROLÓGICOS	28
3.3	PARAMETRIZAÇÃO DOS MÉTODOS DE APRENDIZADO DE MÁQUINAS.....	29
4	RESULTADOS	34
4.1	ANÁLISE DOS DADOS PRÉ-PROCESSADOS	34
4.2	TREINAMENTO DOS ALGORITMOS DE APRENDIZADO DE MÁQUINAS.....	37
4.2.1	XGBoost.....	37
4.2.2	LSTM e variações	38
4.2.3	RNC e variações.....	42
4.2.4	MLP	46
5	CONCLUSÃO E CONSIDERAÇÕES FINAIS.....	50

1 INTRODUÇÃO E CONTEXTUALIZAÇÃO

A irradiação solar no Brasil possui uma média anual muito elevada se comparada a outros países que também se destacam em energia solar instalada. Por exemplo, em países europeus, como Alemanha, Itália, Espanha, França, Holanda e Inglaterra que estão entre os quinze países com maior geração de energia solar fotovoltaica do mundo (IEA, 2021), a média diária do índice de irradiação solar global não ultrapassa 4,64 kWh/m².dia (Global Solar Atlas, 2023); já no Brasil, a média diária de irradiação global é de 5,15 kWh/m².dia (PEREIRA et al., 2017). Atualmente, o Brasil está em décimo quarto lugar de capacidade de energia solar fotovoltaica instalada, e há muito a ser explorado desse mercado de energia elétrica, pois o Brasil possui posição favorável devido às condições climáticas e à grandeza territorial (RANGEL et al. 2016; REI et al., 2017).

Este tema se mostra pertinente quando se fala da matriz energética fotovoltaica no país e o seu crescimento. Com o provável esgotamento das reservas de combustíveis fósseis no mundo e a preocupação com as alterações climáticas, houve uma aceleração das pesquisas voltadas à tecnologia fotovoltaica (OLIVEIRA et al., 2021). Através de um conjunto de elementos como novas regulações e abertura de leilões, o Brasil tem incentivado a inserção da energia solar fotovoltaica na matriz elétrica (MAIA, 2018). Ao levar em consideração esses fatores, o crescimento da geração fotovoltaica na matriz energética tem sido expressivo nos últimos anos.

Ao analisar a evolução temporal da geração de energia elétrica fotovoltaica nos últimos quatro anos, observa-se que a capacidade de geração apresentou um crescimento progressivo. Em 2019, foram gerados 679 MW enquanto, em 2020, foram 877 MW, um aumento de 29% em um ano. Em 2021, a geração alcançou 1438 MW, ou seja, crescimento de 64% em relação ao ano anterior. Por fim, em 2022, a capacidade de geração atingiu 2026 MW, um incremento de 41% em relação ao ano anterior (ONS, 2023).

Esse crescimento da matriz energética fotovoltaica resultou em um volume atual de energia elétrica injetada na rede de distribuição correspondente a 4,4%, com previsão de 7,6% em 2027 (ONS, 2023). Essa quantidade deve ser levada em consideração pelos operadores do Sistema Interligado Nacional (SIN). Contudo, a energia gerada pela irradiação solar é difícil de se prever, visto que depende das condições meteorológicas onde se encontra localizado o sistema fotovoltaico instalado.

1.1 JUSTIFICATIVA

O Brasil é uma região favorecida pela quantidade de irradiação solar que recebe, devido ao seu vasto território, posição geográfica na zona tropical e a outros fatores geográficos. Por causa disso, a energia solar fotovoltaica tem um grande potencial de crescimento ainda não explorado no país.

Uma vez que, em um futuro próximo (2027), estima-se um crescimento de 72% da capacidade instalada de energia fotovoltaica (ONS, 2023), é importante criar uma ferramenta para prever o quanto de energia fotovoltaica será gerada e uma possibilidade é por meio da aplicação de aprendizagem de máquinas e redes neurais.

Aprendizado de máquinas e redes neurais são tecnologias que tiveram avanços importantes e notáveis desempenhos em diversas tarefas, como, por exemplo, identificar poeira e pontos quentes nos módulos fotovoltaicos através de fotos (CIPRIANI et al., 2020). Especificamente as redes neurais de aprendizado supervisionado com reforço, também têm sido utilizadas recentemente pela ferramenta “Chat GPT”, a qual é um *chatbot* que responde soluções precisas do que foi solicitado textualmente pelo usuário.

Assim, neste trabalho de conclusão de curso (TCC), pretende-se realizar um estudo de aplicação de algoritmos de aprendizado de máquina para prever a irradiação solar global do local de análise. Desse modo, pode-se estimar quanto de energia elétrica gerada será injetada em toda a rede

1.2 OBJETIVOS

Este TCC tem como objetivo geral estudar e verificar a viabilidade de utilizar algoritmos de aprendizado de máquinas para prever a irradiação solar em um local e em um período máximo de seis dias.

Como objetivos específicos, propõe-se determinar os algoritmos mais indicados nessa previsão e indicar as vantagens e desvantagens de cada modelo.

1.3 ROTEIRO

Definidos os objetivos, este Trabalho de Conclusão de Curso é separado em cinco capítulos. O capítulo 2 descreve os conceitos da tecnologia fotovoltaica, os principais materiais comerciais atualmente, física dos semicondutores e os métodos de aprendizado de máquinas que serão utilizados.

No capítulo 3, é apresentado o banco de dados meteorológicos a ser explorado, o tratamento dos dados e a parametrização dos métodos de aprendizado de máquinas. Também é apresentada uma comparação da geração de energia elétrica gerada pela usina fotovoltaica com a quantidade de irradiação solar do mesmo período.

Após o capítulo 3 expor toda a metodologia empregada no TCC, no capítulo 4, são apresentados os resultados obtidos pelos treinamentos e validação dos métodos de aprendizado de máquinas. Por fim, no capítulo 5, apresenta-se a conclusão do trabalho, reforçando os resultados alcançados, os objetivos atingidos e as propostas de trabalhos futuros.


2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, serão revisados todos os conceitos teóricos necessários para o desenvolvimento deste TCC. Serão expostos conceitos sobre a energia solar fotovoltaica e dos algoritmos de aprendizado de máquinas utilizados.

2.1 ENERGIA SOLAR

A energia que o sol transmite pode ser chamada de radiação que se propaga em uma onda eletromagnética ou partícula. 81% da energia que é transmitida nessa onda eletromagnética está em uma faixa de comprimento de onda que vai do visível ao infravermelho próximo, conforme mostrado na Figura 1 (PEREIRA et al., 2017).


Figura 1- Espectro da composição da irradiância solar.



Fonte: (PEREIRA et al., 2017)

A irradiância solar que incide no planeta Terra varia por diversos fatores, sendo alguns deles o movimento de rotação terrestre, a translação e as condições meteorológicas da região (MARTINS, et. al., 2007). A transformação da irradiância solar em energia elétrica é feita através dos módulos fotovoltaicos, os quais são compostos geralmente por seis camadas de diferentes materiais. Normalmente, a primeira e a última camada, as externas, são para protegê-los fisicamente e sustentar mecanicamente todas as outras camadas. Já a segunda e a penúltima camada servem para protegê-los contra poeira e umidade, enquanto a terceira tem função antirreflexo, e a quarta camada, que fica no meio, é composta pelas próprias células fotovoltaicas (PORTAL SOLAR, 2023). A Figura 2 mostra a construção desse módulo fotovoltaico descrito anteriormente.

Figura 2 - Camadas que compõem um módulo fotovoltaico monocristalino Si.




Fonte: (PORTAL SOLAR, 2023)

2.1.1 Irradiação solar

A irradiância representa o fluxo de energia radiante instantâneo que incide sobre uma superfície por unidade de área; sua unidade de medida, no Sistema Internacional (SI), é W/m^2 . Já a integral da irradiância no tempo é definida como irradiação solar, ou seja, é a quantidade de energia radiante que incide em uma superfície durante um período de tempo por unidade de área, sua unidade de medida, no SI, é Wh/m^2 (PEREIRA et al., 2017).

A irradiação solar total ao passar pela atmosfera terrestre pode ser dividida em três tipos. A irradiação direta é aquela que não é perturbada até chegar à superfície. Já a irradiação difusa é a refratada por alguma partícula no ar. Por último, a irradiação de albedo é a refletida por qualquer superfície (TIEPOLO et al., 2017). Pode ser vista uma ilustração da natureza dessa grandeza física na Figura 3.


Figura 3 - Natureza da irradiação solar.



Fonte: (TIEPOLO et al., 2017)

Ao considerar toda a irradiação solar que incide sobre a atmosfera, 51% chega ao nível do solo ou do mar (NASA, 2022). Esse comportamento é representado na Figura 4.

Figura 4 - Balanço energético da Terra.




Fonte: (GeoDesign Internacional, 2023)

E essa é a quantidade de irradiação que chega nos módulos fotovoltaicos que produzem a energia elétrica.

2.1.2 Efeitos geográficos e meteorológicos

Devido ao ângulo que a Terra tem em relação ao seu próprio eixo de $23,5^\circ$, a quantidade de energia solar que atinge a superfície terrestre varia e tem uma maior intensidade entre os Trópicos de Capricórnio e de Câncer, região conhecida como zona tropical (VAREJÃO-SILVA, 2006). Esse comportamento pode ser observado na Figura 5, que mostra a distribuição da irradiação global em kWh/m² no mundo.

Figura 5 - Atlas global de irradiação global horizontal.



Fonte: (GLOBAL SOLAR ATLAS, 2023)

A irradiação solar é variante no tempo por causa dos movimentos de rotação e translação da Terra. Este último cria as quatro estações do ano, com máxima irradiação ocorrendo no verão.

A pressão atmosférica e o clima da região também têm grande influência. Por exemplo, o Chile, devido a sua elevada altitude, tem uns dos índices de irradiação global mais altos do mundo. Climas áridos e semiáridos também favorecem esse alto índice de irradiação (PINHEIRO et al., 2019).

No Brasil, todo o seu vasto território é beneficiado pelo alto índice de energia solar. Ao converter os dados da Figura 5 para uma média anual em kWh/m², da forma exposta na Equação (2.1), tem-se:

$$GHI_{ano} = \frac{GHI_{dia} \times d}{1000} \quad (2.1)$$

Onde:


GHI_{dia} - Total diário da irradiação global horizontal [Wh/(m².dia)]

GHI_{ano} - Total anual da irradiação global horizontal [kWh/m²]

d - Números de dias no ano

Na Figura 6, nota-se que a média diária de irradiação global é de 5,15 kWh/(m².dia) no Brasil (PEREIRA et al., 2017), o que é, por sua vez, maior que a melhor incidência de irradiação global horizontal dos países da Europa, a qual é de 4,64 kWh/(m².dia) na Espanha (Global Solar Atlas, 2023). Ademais, os países desse continente, tais como Alemanha, Itália, Espanha, França, Holanda e Inglaterra, estão na lista dos quinze países com maiores capacidade fotovoltaicas instaladas do mundo (IEA, 2021).

Figura 6 - Total diário da irradiação global horizontal média anual.



Fonte: (PEREIRA et al., 2017).

2.1.3 Evolução tecnológicas dos módulos

A tecnologia fotovoltaica refere-se à conversão da luz solar em eletricidade usando semicondutores e eletrólitos. Essa tecnologia é baseada no efeito fotovoltaico e foi descoberta pelo cientista Alexandre Edmond Becquerel no século XIX (APS, 2023).

Por sua vez, o efeito fotovoltaico existe através de materiais semicondutores, pois possuem a característica de ser condutor ou isolante dependendo da sua excitação. Isso ocorre na junção de um substrato p com um substrato n , separados por uma zona de depleção que é chamado de junção pn . O substrato do tipo p tem excesso de lacunas que aceitam os elétrons e o substrato do tipo n tem excesso de elétrons, sendo assim um doador de elétrons (SPROTTE, 2018). Em uma célula fotovoltaica, a absorção de fótons excita essa junção e, quando a energia for suficiente para vencer a zona de depleção, passará para a característica de condução, conforme mostra a Equação 2.

$$E_{fóton} = h \times f \geq E_{depleção} \quad (2.2)$$

Onde:

$E_{fóton}$ - Energia de um fóton [eV]


h - Total anual da irradiação global horizontal [kWh/m²]

f - Frequência [Hz]

$E_{depleção}$ - Energia para passar pela zona de depleção [eV]

Já na Figura 7, observa-se resumidamente como é o funcionamento desse sistema.

Figura 7 - Efeito fotovoltaico na junção pn.



Fonte: (CRESESB, 2014).


Todavia, a primeira célula fotovoltaica só foi criada em 1954. Eram feitas de silício e só tinham 6% de eficiência com elevado custo no processo de fabricação. Assim, a tecnologia só foi utilizada para aplicações espaciais. Por volta dos anos de 1970 a 1980, foram criadas e aprimoradas as primeiras células fotovoltaicas de cristais de silício com eficiência por volta de 10%, com custo de cento e cinco dólares por watt no ano de 1975 até dez dólares por watt no ano de 1985 (IEA, 2020). De todo o período entre a primeira célula fotovoltaica até 2022, muitos materiais foram estudados, testados e desenvolvidos. No entanto, o material que domina

o mercado e é comumente utilizado até os dias atuais é o composto por cristais de silício. Sobre isso, há dois tipos de estruturas de silício que dominam os módulos comerciais no mercado: monocristalinos e multicristalinos.

As células de silício monocristalino são confeccionadas com finas pastilhas do material com alta pureza e espessura de 0,4 a 0,5 milímetros. Sua eficiência está entre 15% a 22% em módulos fotovoltaicos comerciais, com a desvantagem de serem mais caras quando comparadas com os módulos multicristalinos. Já as células de silício multicristalinos são fabricadas a partir de blocos de silícios obtidos por fusão desse semimetal puro em moldes especiais, onde são esfriados lentamente e são solidificados. Nesse processo, os átomos não se organizam num único cristal, mas sim em muitos pequenos cristais, o que justifica o nome do tipo multicristalino. Sua eficiência está entre 14% a 20% em módulos fotovoltaicos comerciais e sua desvantagem é a menor eficiência em relação aos módulos monocristalinos, o que requer um volume maior para gerar a mesma quantidade de energia que um módulo monocristalino. (NUNES et al, 2020)

Ao considerar os avanços da tecnologia e conseqüentemente da eficiência dos módulos, aproximadamente 95% dos módulos fotovoltaicos produzidos no ano de 2021 foram de silício monocristalinos e multicristalinos (FRAUNHOFER, 2022), como pode ser visto na Figura 8.

Figura 8 - Porcentagem da produção global anual de módulos fotovoltaicos.

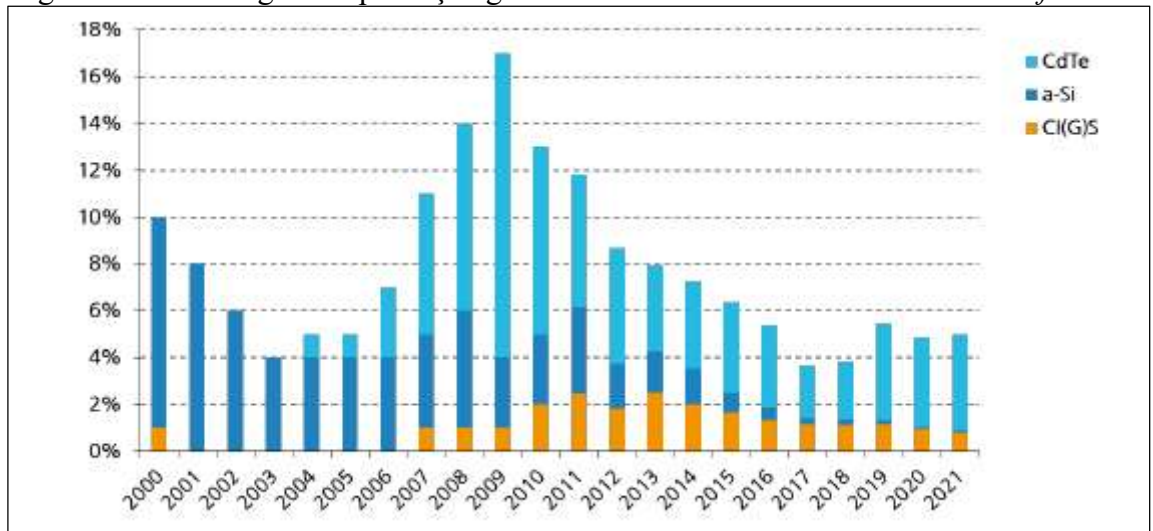


Fonte: (FRAUNHOFER, 2022).

A respeito das demais tecnologias de módulos fotovoltaicos comercializáveis, há três tipos, denominadas *Thin film* (filme fino, em português): as células de silício amorfo, CdTe (telureto de cádmio) e o CIGS (Cobre Índio Gálio Selênio). O *thin film* tem uma baixa

participação no mercado mundial devido à sua eficiência abaixo dos módulos de silício e suas particularidades para instalar, o que exige maior cuidado, planejamento e maior área (FRAUNHOFER, 2022). A Figura 9 mostra a evolução anual do percentual de produção global de módulos fotovoltaicos *thin film*.

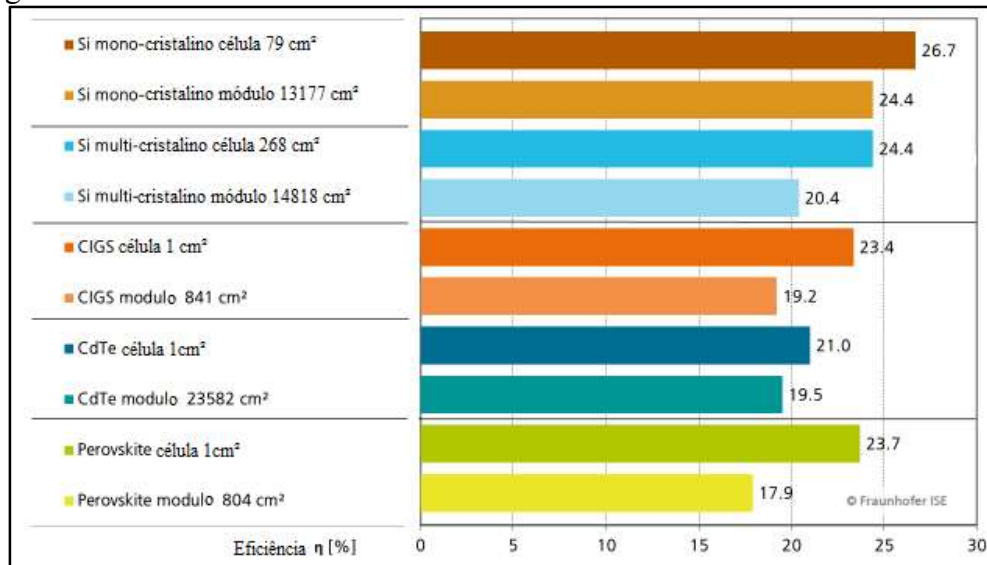
Figura 9 - Porcentagem da produção global anual de módulos fotovoltaicos *thin film*.



Fonte: Adaptado de (FRAUNHOFER, 2022).

Ao analisar a atual eficiência dos módulos comercializados, nota-se que os módulos monocristalinos de silício possuem a melhor eficiência. Mesmo com o custo mais alto de produção, esse tipo de módulo dominou quase 80% da produção mundial dos últimos três anos (FRAUNHOFER, 2022). Na Figura 10, são comparadas a eficiência de cada um dos tipos de módulos. Contudo, deve-se notar que essas são eficiências atingidas em laboratório, ou seja, em condições controladas, o que não reflete necessariamente a realidade de campo.

Figura 10 - Eficiência de células e módulos fotovoltaicos testados em laboratório.



Fonte: Adaptado de (FRAUNHOFER, 2022).

Uma das grandes promessas comerciais para os próximos anos é o módulo de Perovskita. O instituto Fraunhofer ISE foi capaz de atingir recentemente mais de 25% de eficiência para células solares de Perovskita com silício (FRAUNHOFER, 2022). Além disso, eles podem ter uma estrutura flexível, o que os torna úteis para aplicações em superfícies curvas ou em movimento.

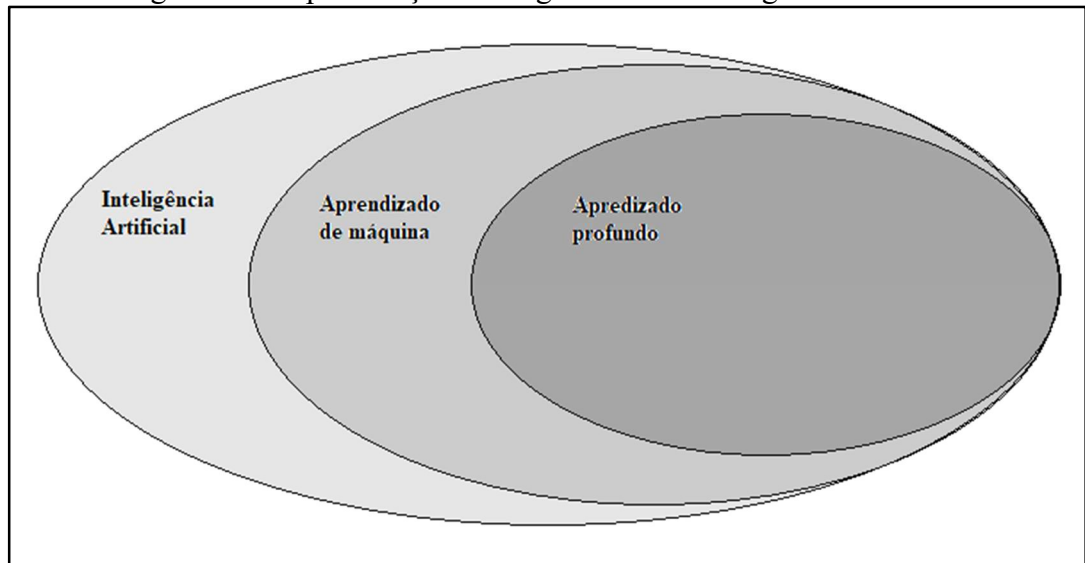
Em resumo, o uso de módulos de Perovskita oferece uma série de vantagens, o que inclui maior eficiência, baixo custo de produção e versatilidade, de modo os tornem competitivos para aplicações em tecnologia de energia solar fotovoltaica. No entanto, é importante destacar que a tecnologia ainda está em desenvolvimento e é necessário realizar mais pesquisas para avaliar sua eficácia e segurança a longo prazo (IEA, 2022).

2.2 ALGORITMOS DE APRENDIZADO DE MÁQUINAS

Para compreender os métodos utilizados neste TCC, é necessário revisar a diferença dos termos inteligência artificial, aprendizado de máquina e aprendizado profundo.

A Figura 11 representa os três conjuntos que serão discutidos e como eles estão relacionados.

Figura 11 - Especificação dos algoritmos de inteligência artificial.



Fonte: Adaptado de (IBM, 2019)

A inteligência artificial é um termo utilizado para descrever um algoritmo capaz de imitar a mente humana, analisar um montante de dados, aprender com eles e apresentar uma solução que o próprio modelo aprendeu a chegar. Já o aprendizado de máquinas é um tipo de inteligência artificial que faz uso de metodologias estatísticas para tomar decisões. De uma forma geral, quanto mais são utilizados os modelos de aprendizado de máquina, melhor serão as decisões deles. No entanto, mesmo ao aumentar cada vez mais a precisão em sua tomada de decisão, algoritmos de aprendizado de máquinas têm a limitação imposta em seu próprio código, o que os tornam incapazes de se adaptarem por conta própria para analisar os dados de forma diferente (IBM, 2019).

Por fim, o aprendizado profundo supre alguns desses problemas, uma vez que os algoritmos dessa subárea da inteligência artificial são capazes de aprender por conta própria, sem necessariamente estar no código tudo o que e como devem fazer, visto que aprenderão a chegar no melhor resultado. (LECUN et al, 2015)

Ademais, são inúmeras as aplicações de redes de aprendizado profundo. Alguns que se destacam em suas áreas são o *ChatGPT*, que traz diversas soluções para programadores e conhecimento geral, capaz de fornecer códigos prontos ou informações com base no método de aprendizado supervisionado e por reforço (*OpenAI*, 2023). Assim como *ChatGPT*, existem outras inteligências artificiais capazes de criar imagens totalmente

originais como o *midjourney*, ou criar músicas de acordo com o humor que é escolhido para transmitir como pode ser feito com o uso do *soundraw.io*.

Na área de energia fotovoltaica, também há muitas pesquisas que utilizam métodos de inteligência artificial. Por exemplo, no artigo *Thermal anomalies detection in a photovoltaic plant using artificial intelligence: Italy case studies* (CIPRIANI et al, 2020), são analisados imagens e vídeos térmicos de quatro usinas fotovoltaicas, cuja soma das potências é de 1,2 MWp. A análise de tal conteúdo seria uma atividade bem maçante para um humano executar, além de possibilitar falhas que um trabalho repetitivo traz ao colaborador. Os dados são coletados automaticamente por drone e, após, processados pelo método das redes neurais convolucionais (RNC), com o objetivo de analisar os dados e identificar anomalias por meio de uma análise rápida e sem a necessidade de desligar parte ou a totalidade da usina.

Além de aumentar a velocidade do processo de identificação de possíveis problemas na usina, o uso da inteligência artificial, nesse estudo, também evitou a alocação de uma pessoa qualificada para trabalhar por horas analisando cada imagem e vídeo, de maneira a permitir que ela possa desempenhar outras atividades.

2.2.1 Redes Neurais

O cérebro humano sempre foi objeto de fascínio por ser uma máquina capaz de processar um grande volume de dados complexos rapidamente, armazenar informações e aprender coisas novas em todo seu período de vida. Um dos elementos fundamentais do sistema nervoso é o neurônio, uma célula altamente especializada. Estima-se que o corpo de um humano adulto contenha cerca de 86 bilhões de neurônios, os quais desempenham um papel crucial na transmissão e no processamento de informações no cérebro (HERCULANO-HOUZEL, 2009).

Em 1943, com a intenção de entender o funcionamento do cérebro, o neurofisiologista Warren McCulloch e o matemático Walter Pitts criaram um modelo computacional para redes neurais baseadas em matemática e lógica de limiar (MCCULLOCH & PITTS, 1943). O modelo pode ser visto como simples hoje em dia, porém, abriu o caminho para o início das redes neurais.

Em 1949, foi descoberto que as conexões entre os neurônios são fortalecidas cada vez que são utilizados (HEBB, 1949). Nos anos seguintes houve diferentes estudos e avanços no entendimento da mente humana.

Em 1960, o cientista Frank Rosenblatt desenvolveu o modelo Perceptron. Esse algoritmo consiste em um modelo com uma ou mais entradas, cada uma com o seu próprio peso, que expressa a importância das respectivas entradas para a saída. A saída do neurônio é determinada pela soma ponderada das entradas multiplicadas pelos seus pesos. Caso o valor seja menor do que o valor limiar (*threshold*), a saída será zero; no caso de ser maior, a saída será um. (MINSKY; PAPERT, 1969)

Uma representação matemática pode ser vista nas Equações (2.3) e (2.4).

No caso um:

$$\sum x_i \times w_i \leq \text{Valor limiar} \quad (2.3)$$

A saída do neurônio terá valor igual a zero.

Já no caso dois:


$$\sum x_i \times w_i > \text{Valor limiar} \quad (2.4)$$

A saída do neurônio terá valor igual a um.

- x_i é a entrada de dados.
- w_i é o peso atribuído a cada entrada de dados.

A Figura 12 é a representação ilustrativa desse modelo.

Figura 12 - Representação do modelo Perceptron.



Fonte: Adaptado de (HAYKIN, 2001).

Esse modelo, mesmo sendo um grande avanço para a época, tem uma limitação crítica de só conseguir resolver funções linearmente separáveis, não sendo aplicável em grande parte aos problemas do dia a dia (NIELSEN, 2019).

2.2.2 Alguns algoritmos conceituados

Nesta subseção, serão discutidos alguns métodos conceituados de aprendizado de máquinas. Particularmente, serão detalhados o *XGBoost* (*eXtreme Gradient Boosting*), LSTM (*Long Short Term Memory*), redes neurais convolucionais (RNC) e a rede perceptron multicamadas (*Multilayer Perceptron*- MLP).

2.2.2.1 XGBoost


O algoritmo *XGBoost* de aprendizado de máquina supervisionado utiliza árvores de decisão para o seu modelo de conjunto. Foi criado por Carlos Guestrin e Tianqi Chen na Universidade de Washington. O algoritmo constrói sequencialmente as árvores de decisão, cada qual corrigindo o erro da anterior até que a condição pré-determinada pelo desenvolvedor seja atingida. Vale ressaltar que, a cada árvore de decisão, são aplicadas penalidades de regularização com o objetivo de evitar o *overfitting*. Essa ferramenta se destaca em problemas de classificação e de regressão, dado que utiliza um processamento paralelo no treinamento, o

que acelera o tempo de convergência, além de contar com parâmetros simples de se ajustarem. Quanto às desvantagens, citam-se o baixo desempenho para dados esparsos e não estruturados e a sensibilidade alta a *outliers* (CHEN, GUESTRIN, 2016)

2.2.2.2 LSTM

A arquitetura de rede neural *Long Short Term Memory* (LSTM) é do tipo rede neural recorrente (RNR). No entanto, difere das outras do mesmo tipo, visto que possui alta capacidade de armazenar informações arbitrárias por um longo período de tempo. Uma de suas principais vantagens é a insensibilidade a *gaps* no valor temporal dos dados analisados. A Figura 13 mostra como a lógica desse método funciona (STAUDEMAYER, 2019).

Figura 13 - Especificação do algoritmo LSTM.



Fonte: Adaptado de (SMAGULOVA et al, 2020).

Na Figura 13, é possível identificar quadrantes separados por retângulos em diferentes cores. O retângulo azul é identificado como *Forget gate*, esse quadrante é responsável por decidir qual informação é importante e qual é irrelevante. A informação da entrada X_t e a *hidden state* h_{t-1} é passada pela função sigmoide, que gera valores de 0 a 1 (SMAGULOVA et al, 2020).

Quanto mais próximo de 1, mais importante o valor é tratado pelo modelo. As variáveis contidas no *Forget gate* da Figura 13 são expostas na Equação (2.5):

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_t) \quad (2.5)$$

- f_t é a saída do *Forget gate* no tempo t .
- X_t é a entrada de dados.
- h_{t-1} é o valor *hidden state*.
- W_f é o peso atribuído a matriz entre o *Forget gate* e a entrada.
- b_t é a conexão *bias* no tempo t .

O quadrante em laranja representa o *Input gate*, o valor da entrada X_t e a *hidden state* h_{t-1} é passada pela função sigmoide para gerar valores de 0 a 1. Em paralelo, a mesma informação é passada pela função *tanh* que cria um vetor com valores de -1 a 1 (SMAGULOVA et al, 2020). As variáveis e as Equações (2.6) e (2.7) estão contidas no *Input gate* da Figura 13 e são expostas abaixo:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2.6)$$

$$\hat{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2.7)$$

- i_t é a saída do *Input gate* no tempo t .
- \hat{c}_t é o vetor gerado pela função *tanh*.
- X_t é a entrada de dados.
- h_{t-1} é o valor *hidden state*.
- W_i é o peso atribuído a matriz entre o *Input gate* e a *Output gate*.
- W_c é o peso atribuído a matriz operadora *tanh* entre o *Input gate* e a *Output gate*.
- b_i e b_c é a conexão *bias* no tempo t .

O quadrante em roxo representa o *Cell state*, em que os dados processados no quadrante em azul e em laranja é multiplicado o valor anterior do *Cell gate* c_{t-1} pelo vetor *Forget gate* f_t . O resultado é somado ponto a ponto com o vetor i_t , resultando na saída c_t (SMAGULOVA et al, 2020). As variáveis e as Equações (2.8) estão contidas no *Cell state* da Figura 13 e são expostas abaixo:

$$c_t = f_t * c_{t-1} + i_t \circ \hat{c}_t \quad (2.8)$$

- c_t é a saída do *Cell state* no tempo t .
- \hat{c}_t é o vetor gerado pela função *tanh*.
- i_t é a saída do *Input gate* no tempo t .
- f_t é a saída do *Forget gate* no tempo t .

E o último quadrante em verde representa o *Output Gate Operation*, em que os valores do *Cell state* e do *Hidden state* anterior são passados pela terceira função sigmoide. Em seguida, o novo valor do *Cell state* é gerado a partir do *Cell state* anterior passado pela função *tanh*. Ambas essas saídas são multiplicadas ponto a ponto. Com base no valor final, a rede decide quais informações o *Hidden state* deve carregar. Este *Hidden state* é usado para previsão (SMAGULOVA et al, 2020). As variáveis e as Equações (2.9) e (2.10) estão contidas no *Cell state* da Figura 13, expostas abaixo:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.9)$$

$$h_t = o_t \circ \tanh(c_t) \quad (2.10)$$

- o_t é a saída da *Output gate*.
- h_t é o valor de saída do *LSTM*.
- W_o é o peso atribuído a matriz entre o *Input gate* e a *Output gate*.
- b_o é a conexão *bias* no tempo t .

As desvantagens do LSTM consistem em: elevada complexidade quando comparado com os tradicionais RNNs; requerer mais dados para treinar e aprender de maneira mais efetiva, o que não é apropriado para dados extremamente não-lineares; também requer um poder de processamento mais robusto (STAUEMEYER, 2019).


2.2.2.3 Redes neurais convolucionais

O método das redes neurais convolucionais (RNC) é um algoritmo de aprendizado profundo que treina conjuntos de dados por meio de convoluções e adiciona pesos para as tomadas de decisões ao invés do uso de camadas com neurônios totalmente conectados para a classificação, procedimento típico de outras redes neurais (GOODFELLOW et al, 2016).

Pode-se dividir esse modelo em cinco partes: a entrada, a convolução, a função de ativação, o *pooling* e o *fully connected*. Na entrada, os dados são recebidos para a classificação ou reconhecimento. Se for uma imagem, por exemplo, haverá três canais de cores RGB com os valores de cada pixel.

A convolução é responsável por fazer uma varredura dos dados, e funciona como filtros que conectam um conjunto pequeno de dados na entrada com um único elemento na camada chamada *hidden neuron*. Esse processo é feito em todos os neurônios ao deslocar o conjunto de dados, que é chamado de *receptive field*. A profundidade de saída de uma convolução é igual à quantidade de filtros aplicados (NIELSEN, MICHAEL, 2019). A Figura 14 ilustra esse processo.

Figura 14 - Exemplo da aplicação da convolução para a criação da *hidden layer*.




Fonte: (GOODFELLOW et al, 2016).

Há várias funções de ativação, como por exemplo a sigmoide, tangente hiperbólica ou a Relu, a qual é a comumente utilizada por trazer acurácias semelhantes ao sigmoide e tangente hiperbólica com menor custo computacional.

Nesse modelo, também é aplicado a *feature max-pooling*, que tem como finalidade resumir a informação da camada anterior, ao retornar o valor de maior peso, ou seja, o maior valor na janela pré-definida para se aplicar esse filtro. A *feature max-pooling* é aplicada individualmente em cada camada que o sistema tiver. Pode-se visualizar uma exemplificação de seu funcionamento na Figura 15.

Figura 15 - Exemplo da aplicação da *feature max-pooling*.



Fonte: (GOODFELLOW et al, 2016).

Por fim, vislumbra-se a última camada de filtro chamada *fully connected*, em que a sua entrada é a saída da camada anterior e sua saída é a do sistema. Nota-se que há uma quantidade de informação relativamente menor do que havia na entrada.


2.2.2.4 *Multilayer Perceptron*

O método *MLP* é uma rede neural com camadas ocultas e que utiliza camadas com neurônios totalmente conectados para a classificação. A técnica utiliza o recurso de *backpropagation*, que é o mecanismo de aprendizado que permite ao *Multilayer Perceptron* ajustar iterativamente os pesos na rede, com o objetivo de minimizar a função de custo.

Pode-se dividir o funcionamento desse método em quatro partes: a inicialização, ativação, treino dos pesos e a iteração. A inicialização é atribuída a valores aleatórios para os pesos e limites, porém esses valores iniciais influenciam o comportamento do método. Assim, recomenda-se começar com valores pequenos, por exemplo, 0,1.

Na ativação, são calculados os valores dos neurônios da camada oculta e depois se aplica o cálculo também na camada de saída. No treino de pesos, calculam-se os erros dos neurônios nas camadas de saída e oculta; além disso, aplicam-se correções com o objetivo de prever valores mais próximos do real. Enfim, o quarto processo é a iteração, isto é, repetir os passos descritos até atingir o critério de parada estabelecido (GOODFELLOW et al, 2016).

Na Figura 16 pode ser vista uma ilustração deste modelo de rede neural.

Figura 16 - Exemplo da rede neural *MLP*.

Fonte: (BENTO, 2021)

3 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo, serão descritos os procedimentos metodológicos abordados neste TCC. Tais procedimentos consistem na análise dos dados obtidos e no seu tratamento, na aplicação dos métodos de treinamentos e na definição dos seus parâmetros.

Foram utilizados os dados via satélite da NASA para treinar a rede neural na localidade escolhida, Campinas - São Paulo. Os modelos de treinamento utilizados foram os *XGBoost*, *Multivariate LSTM*, *Multivariate Stacked LSTM*, *Multivariate RNC*, *Multivariate RNC e LSTM* e o *MLP (Multilayer Perceptron)*.

3.1 BANCO DE DADOS

Na presente pesquisa deste TCC, foram utilizados dados meteorológicos obtidos via satélite disponibilizados pela NASA para treinar as redes neurais e prever a irradiação solar global. Também foram utilizados dados de geração de energia fotovoltaica, disponibilizados pela *PV Operation*, de uma usina em pleno funcionamento. Ambos os dados foram registrados de hora em hora e são da mesma coordenada geográfica de latitude -22,7677 e longitude -47,0127, na cidade de Campinas no estado de São Paulo.

Os dados meteorológicos e de geração fotovoltaica contemplam o mesmo período de 1º de janeiro de 2021 até 3 de janeiro de 2022 em amostragens de hora em hora. Além disso, são categorizados em 31 tipos conforme especificado no Quadro 1.

Quadro 1 – Dados meteorológicos.

Dado	Significado	Unidade
PS	Pressão na superfície	(kPa)
WS10M	Velocidade do vento a 10 metros da superfície	(m/s)
WD10M	Direção do vento a 10 metros da superfície	(°)
WS50M	Velocidade do vento a 50 metros da superfície	(m/s)

WD50M	Direção do vento a 50 metros da superfície	(°)
QV2M	Umidade específica a 2 metros da superfície	(g/kg)
RH2M	Umidade relativa a 2 metros da superfície	(%)
PRECTOTCORR	Precipitação	(mm/h)
T2M	Temperatura a 2 metros da superfície	(°C)
T2MDEW	Temperatura de ponto de orvalho	(°C)
T2MWET	Temperatura de bulbo	(°C)
ALLSKY_SFC_SW_DWN	Soma da radiação solar de ondas curtas que incide sobre a superfície terrestre	(Wh/m ²)
CLRSKY_SFC_SW_DWN	Soma da radiação solar de ondas curtas que incide sobre a superfície terrestre na ausência de nuvens	(Wh/m ²)
ALLSKY_KT	Fração que representa a clareza da atmosfera	Adimensional
ALLSKY_SRF_ALB	A fração da radiação solar refletida pela superfície dividida pelo total de luz incidente na atmosfera	Adimensional
SZA	Ângulo entre os raios solares e a direção	(°)
ALLSKY_SFC_PAR_TOT	Soma da radiação fotossintética ativa solar que incide sobre a superfície terrestre	(Wh/m ²)
CLRSKY_SFC_PAR_TOT	Soma da radiação fotossintética ativa solar que incide sobre a superfície terrestre na ausência de nuvens	(Wh/m ²)
ALLSKY_SFC_UVA	Soma da radiação solar UVA	(Wh/m ²)


ALLSKY_SFC_UVB	Soma da radiação solar UVB	(Wh/m ²)
ALLSKY_SFC_UV_INDEX	Medida de intensidade da radiação UV	Adimensional

Fonte: (NASA, 2022).

Conforme será melhor detalhado na seção 3.2, todos esses dados serão analisados e tratados para conferir sua integridade, diagnosticar possíveis *outliers* e verificar as suas correlações com a variável alvo que é a “ALLSKY_SFC_SW_DWN”. Além desses dados, há também o já mencionado dado de geração de energia fotovoltaica. O nome que será adotado para essa usina será “Usina 01” devido à requisição de sigilo por parte do proprietário.

Na Figura 17, foi utilizado um período de 31/12/2020 às 21:00:00 até 06/01/2021 às 23:00:00, ou seja, seis dias dos dados de geração de energia fotovoltaica da Usina 01 em cinza em paralelo com os dados de irradiação solar em laranja na mesma coordenada geográfica.

Figura 17 - Irradiação solar x geração de energia fotovoltaica da Usina 01.



Fonte: Autoria própria.

Com a comparação desses dados na Figura 17, nota-se uma correlação entre o registro de energia elétrica fotovoltaica gerada pela Usina 01 e os dados registrados via satélite da NASA da irradiação solar que incide sobre a superfície terrestre. Sendo assim adequado ao esperado.

3.2 TRATAMENTO DOS DADOS METEOROLÓGICOS

A organização, tratamento e treinamento dos modelos dos algoritmos de aprendizado de máquinas foram feitos utilizando a linguagem de programação Python através do ambiente do JupyterLab. Antes, entretanto, foi feito um pré-processamento deles. Nesse processo, os dados disponibilizados pela NASA foram exportados em formato CSV, todos em uma única coluna e há uma vírgula para separar cada tipo diferente de parâmetro. Para facilitar a análise de todos esses dados, criou-se uma tabela, através da biblioteca Pandas, com uma coluna para cada parâmetro.

Com a tabela montada, nota-se que, no período da noite, há registros de valores negativos “-999.00”. Esses valores serão considerados como ruídos nos dados de irradiação. Como o interesse do estudo é nos horários diurnos, em que tem potencial de gerar energia solar fotovoltaica, foram retiradas todas as linhas de dados nesses horários noturnos. Portanto, os dados estudados compreendem ao período de seis horas da manhã até às seis horas da tarde.

Vencida a etapa de pré-processamento, adentra-se no processamento de dados. Nessa etapa, é aplicada a matriz de correlação de Pearson com a finalidade de ter uma visão geral das correlações de todas essas variáveis em relação a de interesse, que é “ALLSKY_SFC_SW_DWN”.

Em seguida, são gerados gráficos no formato *boxplot* para observar, nas variáveis de interesse, as suas dispersões, simetrias, limites inferiores e superiores além de *outliers*. Por fim, antes de aplicar os métodos conforme já mencionado no Capítulo 2, os dados serão transformados e normalizados.

Após o treinamento e a validação, tem-se a etapa de pós-processamento dos dados, em que será aplicada a transformada inversa e, assim, a desnormalização.

3.3 PARAMETRIZAÇÃO DOS MÉTODOS DE APRENDIZADO DE MÁQUINAS

Foi utilizado o *XGBoost* como primeiro método por causa de sua robustez, bom desempenho e simples aplicabilidade. A taxa de aprendizado utilizada é de 6×10^{-3} e o critério de parada foi a 180ª etapa ou se não há melhora no resultado em três etapas seguidas. Os critérios desse primeiro método foram escolhidos de forma empírica. Assim, é possível ter uma noção de qual será a maneira mais adequada de se abordar esses dados a partir do seu comportamento, como, por exemplo, uma noção de quantas épocas será necessária ou se será necessário parâmetros de velocidade de aprendizado mais conservadores e principalmente verificar que esses dados convergem. Os parâmetros adotados são mostrados no Quadro 2

Quadro 2 – Parâmetros utilizados no *XGBoost*.

<i>eta</i>	0,03
<i>max_depth</i>	180
<i>colsample_bytree</i>	0,95
<i>alpha</i>	0,1
<i>lambda</i>	0,15
<i>gamma</i>	0,1
<i>min_child_weight</i>	0,1
<i>n_jobs</i>	-1

Fonte: Aatoria própria.

- *eta*: Após cada etapa de aumento, pode obter diretamente os pesos dos novos recursos, e o *eta* reduz os pesos dos recursos para tornar o processo de aumento mais conservador.
- *max_depth*: Máxima profundidade da árvore. Quanto maior mais complexo e mais chances de *overfitting*.
- *colsample_bytree*: É a proporção de subamostra de colunas ao construir cada árvore. A subamostragem ocorre uma vez por cada árvore construída.

- *alpha e lambda*: Termos de regularização de pesos. Aumentar esses valores torna o modelo mais conservador.
- *gamma*: Redução mínima de perda necessária para fazer uma nova partição em um nó de folha na árvore. Quanto maior for o gama, mais conservador será o algoritmo.

Após a convergência dos dados com o método *XGBoost*, aplica-se o método *Multivariate LSTM* com uma taxa de aprendizado de 6×10^{-3} . Os critérios de parada são de 120 épocas ou se não houver melhora no resultado em dez épocas seguidas. Esses critérios se repetem para todos os métodos de redes neurais utilizados. Os parâmetros adotados são mostrados no Quadro 3.

Quadro 3 – Parâmetros LSTM

<i>Units</i>	100
<i>Return_sequences</i>	<i>True</i>
<i>Dense</i>	200, <i>activation='relu'</i>
<i>Dropout</i>	0,1
<i>Optimizer</i>	Adam
<i>Callback</i>	<i>early_stopping</i>

Fonte: Autoria própria.

- *Unit*: Inteiro positivo, dimensionalidade do espaço de saída.
- *Return_sequences*: Booleano. Se deve retornar a última saída na sequência de saída ou a sequência completa.
- *Dense*: Camada onde cada neurônio está conectado a todos os neurônios da próxima camada.
- *Dropout*: É a proporção de subamostra de colunas ao construir cada árvore. A subamostragem ocorre uma vez por cada árvore construída.
- *Optimizer*: Adam é um método de descida de gradiente estocástico baseado na estimativa adaptativa de momentos de primeira e segunda ordem.

- *Callback: early_stopping* é uma ferramenta utilizada para parar o treinamento assim que ele começa a perder a performance.

Como não foi apresentada nenhuma divergência, segue para o próximo passo, que é aplicar novamente o método LSTM, especificamente uma técnica conhecida como *Multivariate Stacked LSTM*, a qual consiste em aplicar duas vezes o método LSTM com o objetivo de obter *hidden layers* mais profundas (MA et al, 2022). Utilizar um segundo treinamento LSTM na saída do primeiro permite também um menor esforço de processamento (RUDER, 2017). A taxa de aprendizado utilizada é de 3×10^{-3} . Os parâmetros adotados são mostrados no Quadro 4.

Quadro 4 – Parâmetros *Stacked LSTM*

<i>Units</i>	250
<i>Return_sequences</i>	<i>True</i>
<i>Dense</i>	150, <i>activation='relu'</i>
<i>Dropout</i>	0,1
<i>Optimizer</i>	Adam
<i>Callback</i>	<i>early_stopping</i>

Fonte: Autoria própria.

O método RNC também é aplicado a uma taxa de aprendizado de 6×10^{-3} , porém, são utilizados os parâmetros mostrados no Quadro 5.

Quadro 5 – Parâmetros RNC.

<i>Filters</i>	48
<i>Kernel_size</i>	2
<i>Dense</i>	48, <i>activation</i> ='relu'
<i>Callback</i>	<i>early_stopping</i>
<i>Optimizer</i>	Adam
<i>Padding</i>	Causal

Fonte: Autoria própria.

- *Filters*: Inteiro positivo, dimensionalidade do espaço de espessura do *layer*.
- *Kernel_size*: Filtros convolucionais.
- *Dense*: Camada onde cada neurônio está conectado a todos os neurônios da próxima camada.
- *Padding*: É uma ferramenta para estender a área de convolução.
- *Optimizer*: utilizado o Adam, que é um método de descida de gradiente estocástico baseado na estimativa adaptativa de momentos de primeira e segunda ordem.
- *Callback*: *early_stopping* é uma ferramenta utilizada para parar o treinamento assim que ele começa a perder a performance.

É aplicado novamente o método RNC, porém, agora, em conjunto com o LSTM. Este é um método aplicado na literatura em situações em que a entrada e a saída tem dependência temporal, pois apresenta melhor desempenho em relação à RNC ou LSTM separados (SHI et al, 2015). Os parâmetros são os mesmos dos Quadros 5 e 3.

Aplicando o método MLP com uma taxa de aprendizado de 2×10^{-3} , os parâmetros adotados são mostrados no Quadro 6.

Quadro 6 – Parâmetros MLP

<i>TimeDistributed Dense</i>	200, <i>activation='relu'</i>
<i>TimeDistributed Dense</i>	150, <i>activation='relu'</i>
<i>TimeDistributed Dense</i>	100, <i>activation='relu'</i>
<i>TimeDistributed Dense</i>	50, <i>activation='relu'</i>
<i>Optimizer</i>	Adam
<i>Dropout</i>	0,1

Fonte: Autoria própria.

- *TimeDistributed Dense*: Aplica a mesma densidade para cada passo.

Os resultados dos treinamentos e validações dos métodos que serão discutidos na seção 4 foram analisados pelas métricas RMSE e a variável com nome *Loss* entre a amostra de treino e a amostra de validação. O valor RMSE, que significa “*Root Mean Square Error*”, é o desvio padrão dos resíduos, ou seja, erros de previsão. Além disso, informa a concentração dos dados em torno da linha de melhor ajuste; quanto menor o valor, melhor o método é em prever o resultado esperado.

A métrica *Loss* é o MSE, que significa “*Mean Square Error*”, ou seja, o erro quadrático médio é medido como a média da diferença quadrada entre as previsões e os dados observados reais. Esta métrica dá ênfase na magnitude média do erro e, devido ao quadrado, as previsões que estão distantes dos valores reais são fortemente penalizadas em comparação com as previsões menos desviadas (FILHO, 2023).


4 RESULTADOS

Neste capítulo, divulgam-se os resultados obtidos a partir da aplicação dos procedimentos metodológicos descritos no capítulo 3.

4.1 ANÁLISE DOS DADOS PRÉ-PROCESSADOS

A fim de adquirir uma visão geral das correlações de todas as trinta e uma variáveis em relação a de interesse, “ALLSKY_SFC_SW_DWN”, foi aplicada a matriz de correlação de Pearson, mostrada na Figura 18.

Figura 18 - Matriz de correlação de Pearson das variáveis meteorológicas.

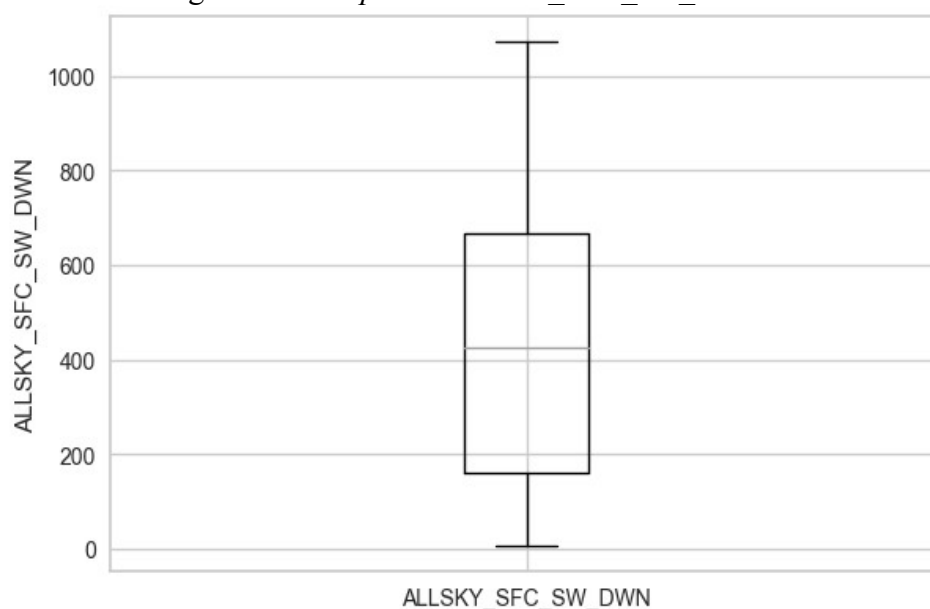


Fonte: Autoria própria.

De acordo com essa matriz, a variável de interesse “ALLSKY_SFC_SW_DWN” apresenta correlação forte com as outras irradiações solares, o que já era esperado. Entretanto, notam-se correlações também com “WD10M”, “T2M” e “T2MWET”. Assim, será verificada a existência de *outliers* nesses dados, uma vez que pode resultar em divergência nos treinamentos dos modelos. Nessa verificação, é importante cautela, visto que, ao retirar algum dado por engano, pode-se alterar a base de dados e condicionar os modelos a treinar com dados distorcidos. Por conseguinte, isso pode trazer previsões com alta precisão, porém irreais.


A seguir, nas Figuras 19, 20, 21 e 22, são gerados gráficos no formato *boxplot*.

Figura 19 - *Boxplot* “ALLSKY_SFC_SW_DWN”.

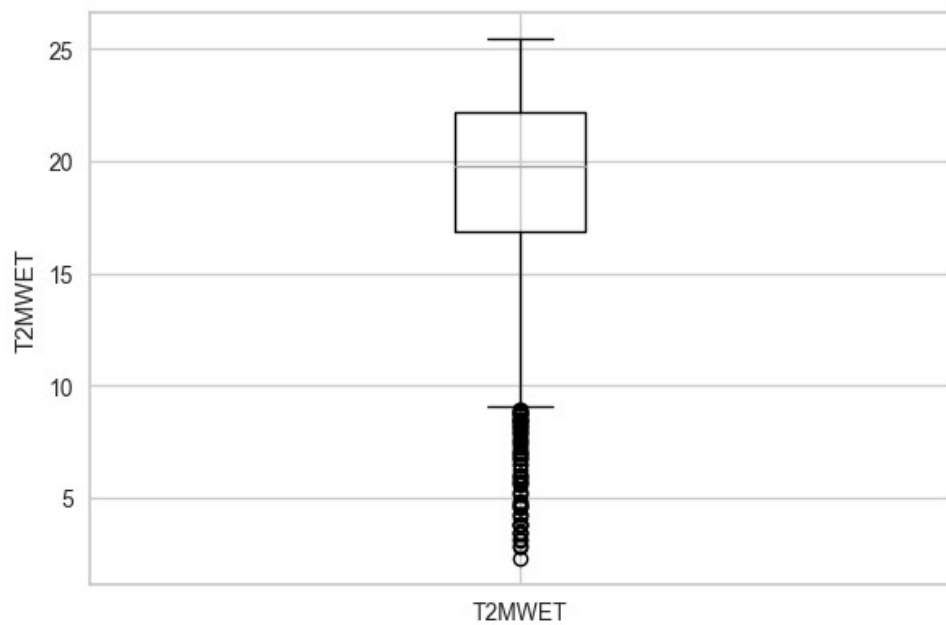


Fonte: Autoria própria.

Na Figura 19, há um comportamento regular, visto que não é identificado *outlier* algum. Logo, os limites inferiores e superiores são conforme o esperado para a região de Campinas, São Paulo.

Figura 20 - *Boxplot* “T2M”.

Fonte: Autoria própria.


Figura 21 - *Boxplot* “T2MWET”.

Fonte: Autoria própria.

Na Figura 20 e 21, que são a temperatura a dois metros da superfície e a temperatura de orvalho respectivamente, demonstram possíveis *outliers*. Contudo, ao verificar os registros de temperaturas em outra fonte de dados meteorológica disponibilizados no site *Weather Spark*

da empresa *Cedar Lake Ventures, Inc.*, repara-se que esses valores de temperatura acontecem todos os anos poucas vezes; logo, não é adequado classificá-los como *outliers*.

Figura 22 - *Boxplot* “WD10M”.



Fonte: Autoria própria.

Por fim, a Figura 22 é semelhante ao comportamento da variável “ALLSKY_SFC_SW_DWN” com um comportamento regular, pois não é identificado *outlier* algum e os limites inferiores e superiores são conforme o esperado para a região.

4.2 TREINAMENTO DOS ALGORITMOS DE APRENDIZADO DE MÁQUINAS


Após o pré-processamento e as análises realizadas com a matriz de correlação e o *boxplot*, parte-se para o treinamento dos algoritmos de aprendizado de máquinas.

4.2.1 XGBoost

A convergência ocorreu na etapa 138 de treinamento. Na Figura 23, podem ser acompanhados os valores RMSE de cada etapa. Dela, pode ser constatado que os valores RMSE

da validação estão próximos dos valores obtidos no treino, o que é um bom indicativo de que não houve *overfitting* no treinamento.

Figura 23 - Etapa vs RMSE treino e validação *XGBoost*.




Fonte: Autoria própria.

4.2.2 LSTM e variações


A partir dos dados convergidos com o método *XGBoost*, aplica-se o método LSTM com uma taxa de aprendizado de 6×10^{-3} .

A convergência ocorreu na época 55 de treinamento. Nas Figuras 24 e 25, podem-se acompanhar os valores RMSE e *Loss* de cada época.

Figura 24 - Época vs RMSE treino e validação LSTM.

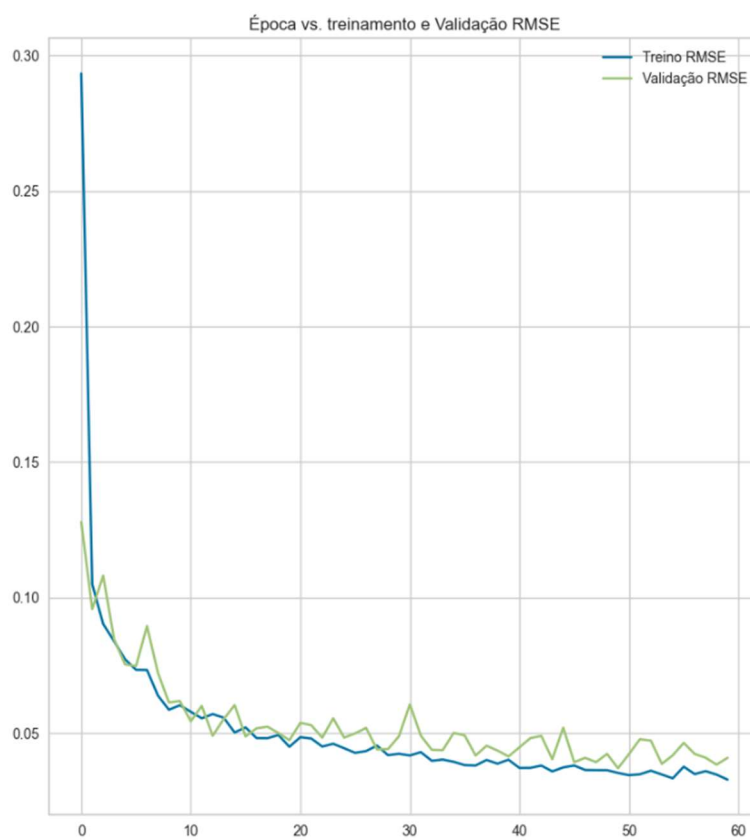


Fonte: Autoria própria.


Figura 25 - Época vs *Loss* treino e validação LSTM.

Fonte: Autoria própria.

No método *Stacked LSTM*, a convergência ocorreu na época 61 de treinamento de acordo com os critérios estabelecidos no Capítulo 3. Na Figura 26 e 27 pode-se acompanhar os valores RMSE e *Loss* de cada época.

Figura 26 - Época X RMSE treino e validação *Stacked LSTM*.

Fonte: Autoria própria.


Figura 27 - Época X *Loss* treino e validação *Stacked LSTM*.

Fonte: Autoria própria.


4.2.3 RNC e variações

No método RNC, a convergência ocorre na época 51 de treinamento com os critérios estabelecidos no Capítulo 3. Nas Figuras 28 e 29, podem ser acompanhados os valores RMSE e *Loss* de cada época. Este método obteve os valores mais baixos de RMSE e *Loss*.

Figura 28 - Época X RMSE treino e validação RNC.




Fonte: Autoria própria.

Figura 29 - Época X *Loss* treino e validação RNC.

Fonte: Autoria própria.


É aplicado novamente o método RNC, porém, agora, em conjunto com o LSTM. A convergência ocorreu na época 32 de treinamento. Nas Figuras 30 e 31, pode-se acompanhar os valores RMSE e *Loss* de cada época. Repara-se que os valores de RMSE ficaram mais instáveis em algumas épocas. E quando comparado ao método RNC, o RNC LSTM teve um desempenho um pouco abaixo, com valores de RMSE e *Loss* maiores.

Figura 30 - Época X RMSE treino e validação RNC e LSTM.



Fonte: Autoria própria.

Figura 31- Época X Loss treino e validação RNC e LSTM.

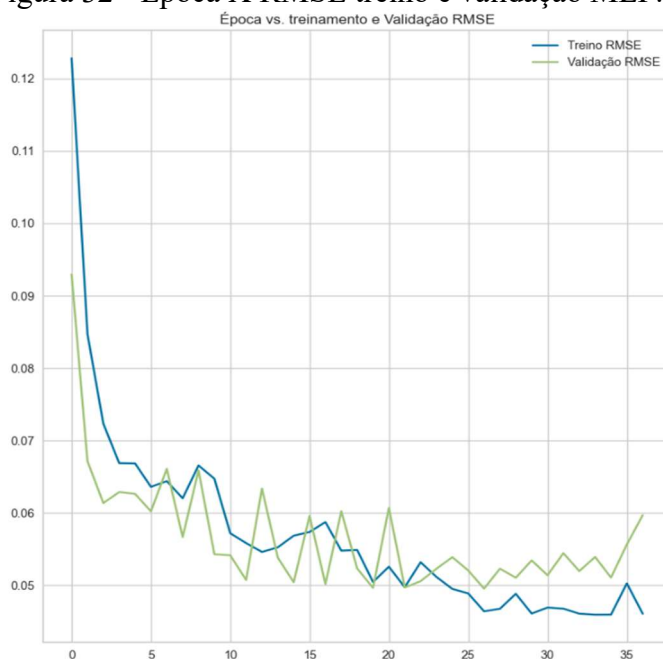


Fonte: Autoria própria.

4.2.4 MLP

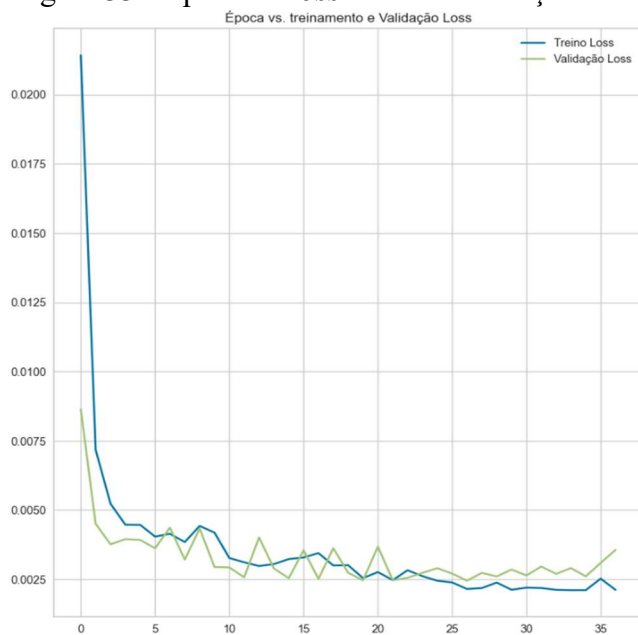
A convergência ocorreu na época 37 de treinamento. Nas Figuras 32 e 33, são mostrados os valores RMSE e *Loss* de cada época.

Figura 32 - Época X RMSE treino e validação MLP.



Fonte: Autoria própria.

Figura 33 - Época X *Loss* treino e validação MLP.



Fonte: Autoria própria.

Repara-se que houve um pouco de instabilidade e apesar de os valores RMSE e *Loss* terem tido quase o melhor desempenho no treinamento, na validação foi o pior modelo em comparação com os outros. Em resumo, a partir dos treinamentos e validações dos algoritmos, obtêm-se os valores de RMSE e *Loss* máximos e mínimos apresentados nas Tabelas 1 e 2.

Tabela 1 – RMSE e *Loss* de treino para cada modelo de aprendizado de máquina.

	Máx. RMSE	Mín. RMSE	Máx. <i>Loss</i>	Mín. <i>Loss</i>
<i>XGBoost</i>	0,28456	0,0451	-	-
LSTM	0,4646	0,0486	0,2159	0,0024
<i>Stacked LSTM</i>	0,2336	0,0494	0,0799	0,0024
RNC	0,2107	0,0390	0,0652	0,0015
RNC + LSTM	0,2169	0,0469	0,0689	0,0022
MLP	0,1228	0,0460	0,0214	0,0021

Fonte: Autoria própria.

Tabela 2 – RMSE e *Loss* de validação para cada modelo de aprendizado de máquina


	Máx. RMSE	Mín. RMSE	Máx. <i>Loss</i>	Mín. <i>Loss</i>
<i>XGBoost</i>	0,27550	0,05865	-	-
LSTM	0,1168	0,0578	0,0136	0,0033
<i>Stacked LSTM</i>	0,1416	0,0484	0,0201	0,0023
RNC	0,1226	0,0532	0,0150	0,0028
RNC + LSTM	0,1280	0,0475	0,0164	0,0023
MLP	0,0929	0,0597	0,0086	0,0036

Fonte: Autoria própria.

Nota-se o progresso obtido em cada modelo utilizado no início, que tem os seus valores máximos de RMSE e *Loss*, comparado com o final, que demonstra seus valores mínimos. Todos os modelos convergem em seus treinamentos e validações. Alguns métodos tiveram um

desempenho melhor no treinamento, porém, na validação, foi conseguido manter o desempenho. Na validação, o método RNC LSTM foi o que obteve valores RMSE e *Loss* mais baixos. Portanto, entre os modelos analisados, este foi o que previu valores mais próximos do valor real dos dados. Para uma análise visual dos valores que cada método de aprendizado de máquina gerou, foi realizada a transformação inversa dos valores normalizados de irradiação previstos e comparados com os verdadeiros dados medidos de irradiação. Os resultados obtidos podem ser observados na Figura 34.

Figura 34- Previsão da irradiação “ALLSKY_SFC_SW_DWN” por cada modelo.




Fonte: A autoria própria.

A Figura 34 demonstra a irradiação “ALLSKY_SFC_SW_DWN”, parâmetro alvo, e os outros seis modelos e variações de aprendizado de máquina prevendo o comportamento do alvo durante os dias 18/10/2021 a 23/10/2021. O comportamento atípico da irradiação nos primeiros dias deve-se ao tempo ter nuvens e o céu estar parcialmente ou totalmente encoberto.

O registro dessa condição meteorológica pode ser visto na Figura 35 e na Figura 36 referentes ao dia 18/10/2021 e ao dia 22/10/2021, que marca o início dos dias com condições climáticas favoráveis para a irradiação solar. Uma demonstra que o céu estava com uma alta taxa de nuvens encobrindo o céu e na outra que o céu estava limpo. Esses dados são originários


da estação meteorológica do Aeroporto Internacional de Viracopos/Campinas, uma região próxima ao da Usina 01.

Figura 35- Densidade de nuvens no céu dia 18/10/2021.



Fonte: Adaptado de (WEATHER PARK, 2023)

Figura 36 - Densidade de nuvens no céu dia 22/10/2021.



Fonte: Adaptado de (WEATHER PARK, 2023)

5 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Este TCC tem, como objetivo, estudar o uso de algoritmos de aprendizado de máquinas para prever a irradiação solar que incide sobre Campinas (SP). Foram utilizados inicialmente os dados da Usina 01 como meio de validação dos dados de irradiação “ALLSKY_SFC_SW_DWN” fornecidos pela NASA. Essa comparação é mostrada na Figura 14 e nota-se que está coerente e há relação entre as duas séries temporais.

Como os dados utilizados neste estudo não foram pré-processados ou já utilizados em trabalhos acadêmicos, houve a necessidade de utilizar métodos comumente expressos na literatura para o tratamento e interpretação do mesmo. Na Figura 18, utiliza-se o mapa de calor de Pearson e da Figura 19 à Figura 22 gráficos *boxplot*, um para descobrir as correlações com a variável alvo “ALLSKY_SFC_SW_DWN” e o outro para identificar o comportamento e eventuais *outliers* das variáveis identificadas com certo grau de correlação.

No capítulo 4, nota-se que os métodos *XGBoost* e MLP, mesmo não sendo muito eficientes pelas limitações já mencionadas, obtiveram resultados melhores no treinamento que os métodos RNC, RNC LSTM e LSTM. Contudo, quando na etapa de validação, os métodos *XGBoost* e MLP tem os maiores valores de RMSE e *Loss*, o que significa que o valor previsto por eles está mais longe do valor verdadeiro em relação ao que os métodos RNC, RNC LSTM e LSTM previram.

A partir dos dados de validação e com os critérios de limitações escolhidos, o melhor modelo para essa aplicação foi o RNC LSTM, que obteve os menores valores de RMSE e *Loss* na validação. Portanto, os objetivos específicos de determinar os melhores algoritmos foram atingidos, mas também o objetivo geral deste trabalho de conclusão de curso em elaborar um estudo sobre a aplicação de redes neurais para prever a irradiação solar na cidade de Campinas (SP) para aplicações na geração de energia fotovoltaica foi atingido.

Como trabalho futuro, é possível automatizar o processo de aquisição dos dados meteorológicos e os tratamentos desenvolvidos aqui para criar um programa capaz de selecionar regiões diferentes de acordo com a necessidade. Outro estudo interessante, caso houvesse acesso a dados registrados pela própria usina de geração de energia, medidores de temperatura, os dados das estações meteorológicas internas das usinas, velocidade do vento, é o de compará-los com os fornecidos pela NASA e tentar chegar no mesmo resultado apresentado nesse Trabalho de Conclusão de Curso.

REFERÊNCIAS

- APS - *ADVANCING PHYSICS. American physics society sites*. Disponível em: <www.aps.org/publications/apsnews/200904/physicshistory>. Acesso em: 15 mar. 2023.
- BENTO, CAROLINA. 2021. *Multilayer perceptron explained with a real life example and Python code sentiment analysis*. Disponível em: <<https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis>>. Acesso em: 01 mai. 2022.
- CHEN, Tianqi. *Introduction to Boosted Trees*. 2014. Disponível em: <https://web.njit.edu/~usman/courses/cs675_spring20/BoostedTree.pdf>. Acesso em: 01 mai. 2022.
- CIPRIANI, G. et al. *Convolutional Neural Network for Dust and Hotspot Classification in PV Modules*. 2 dez. 2020.
- CRESESB. *Manual de Engenharia para Sistemas Fotovoltaicos*. CEPEL - CRESESB. Rio de Janeiro - Brasil, 2014.
- FILHO, M. *RMSE (Raiz do Erro Quadrático Médio) em Machine Learning*. Disponível em: <mariofilho.com/rmse-raiz-do-erro-quadratico-medio-em-machine-learning>. Acesso em: 20 mai. 2023).
- FRAUNHOFER, *Institute for Solar Energy Systems ISE*. 2022 Disponível em: <<https://www.ise.fraunhofer.de/>>. Acesso em: 05 mar. 2023.
- GEODESIGN INTERNACIONAL. *Conhecimento básico sobre o recurso solar*. Disponível em: < http://recursosolar.geodesign.com.br/Pages/Sol_Rad_Basic_RS.html >. Acesso em: 22 jan. 2023.
- GLOBAL SOLAR ATLAS. *Atlas global de irradiação global horizontal*. Disponível em: <<https://globalsolaratlas.info/map>>. Acesso em: 02 mar. 2023.
- GOODFELLOW, I. et al. *Deep Learning*. MIT Press, Cambridge, MA. 2016.
- GOETZBERGER, A.; HOFFMANN, V. U. *Photovoltaic Solar Energy Generation*. Munique: Fraunhofer ISE, Springer, c2005.
- HAYKIN, S. *Redes Neurais- Princípios e Práticas*. BOOKMAN, São Paulo, 2ª ed. 2001. 900 p.
- HEBB, D. O. *The organization of behavior; a neuropsychological theory*. Wiley. 1949.
- HERCULANO - HOUZEL, Suzana. *Pílulas de neurociência para uma vida melhor*. Rio de Janeiro: Sextante, 2009.

IBM. *AI, machine learning and deep learning: What's the difference?*. Disponível em: <<https://admin02.prod.blogs.cis.ibm.net/blogs/systems/ai-machine-learning-and-deep-learning-whats-the-difference/>>. Acesso em: 02 mar. 2023.

IEA. *Renewables Data Explorer*, IEA, Paris. Disponível em: <<https://www.iea.org/data-and-statistics/data-tools/renewables-data-explorer>>. Acesso em: 20 mar. 2022.

IRENA - International Renewable Energy Agency. **Renewable capacity statistics**. Abu Dhabi, 2023.

JÄGER, K. et al. *Solar Energy Fundamentals, Technology, and Systems*. Delft University of Technology, 2014.

LECUN, Y; BENGIO, Y; HINTON, G. **Deep learning**. Nature. New York: Macmillan Publishers Limited, 2015. Volume 521. p. 436-444.

MCCULLOCH, W., PITTS, W., “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, **The Bulletin of Mathematical Biophysics**, Vol. 5, No. 4, pp. 115 – 133, 1943.

MA, M. et al. *Predicting machine's performance record using the stacked long short-term memory (LSTM) neural networks*. 2022. Disponível em: <<https://aapm.onlinelibrary.wiley.com/doi/full/10.1002/acm2.13558>>. Acesso em: 15 fev. 2023.

MAIA, R. S.. 2018. Energia Solar: **O desenvolvimento de um novo mercado**. Rio de Janeiro: UFRJ/ Escola Politécnica, 2018. 18, 71 p.: il.; 29,7 cm.. <http://monografias.poli.ufrj.br/monografias/monopoli10024980.pdf>.

MARTINS, F. R.; PEREIRA, E. B.; ABREU, S. L. *Satellite-derived solar resource maps for Brazil under SWERA Project*. Solar Energy, Vol. 81, Issue 4, Pp 517-528. 2007.

MINSKY, M. L. and PAPERT, S. A. (1969) Perceptrons. MIT Press, Cambridge.
NASA. *Prediction of world wide resources*. Disponível em: <<https://power.larc.nasa.gov/data-access-viewer/>>. Acesso em: 02 jan. 2023.

NIELSEN, M. *Neural Networks and Deep Learning*. Disponível em: <<http://neuralnetworksanddeeplearning.com>>. Acesso em: 15 fev. 2023.

NUNES, H. M. et al. Estudo comparativo técnico-financeiro de usinas fotovoltaicas utilizando módulos de silício monocristalinos e policristalinos. **VIII Congresso Brasileiro de Energia Solar**. Fortaleza, 01 a 05 de jun. 2020.

ONS. **Evolução da capacidade instalada no SIN - Julho 2023/ Dezembro 2027**. Disponível em: <<https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>>. Acesso em: 25 abr. 2023.

ONS. **Histórico de geração de energia fotovoltaica no Brasil**. Disponível em: <https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx>. Acesso em: 25 abr. 2023.

OpenAI. **Chat GPT**. Disponível em: <<https://openai.com/gpt-4>>. Acesso em: 26 abr. 2023.

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>.

PORTAL SOLAR. **Como funciona o painel solar fotovoltaico?** Disponível em: <<https://www.portalsolar.com.br/como-funciona-o-painel-solar-fotovoltaico.html>>. Acesso em: 15 fev. 2023.

REN21, **Renewables Global Status Report**. 2014

RUDER, S. **Deep Learning for NLP Best Practices**. Disponível em: <http://runder.io/dee-p-learning-nlp-best-practices/>, Acesso em: 04 abr. 2023)

SHI, X. et al. **Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting**. Disponível em: <<https://arxiv.org/abs/1506.04214>>. Acesso em: 22 fev. 2023.

SMAGULOVA, K.; JAMES, A.P. *Overview of Long Short-Term Memory Neural Networks*. In: James, A. (eds) **Deep Learning Classifiers with Memristive Networks. Modeling and Optimization in Science and Technologies**, vol 14. Springer, Cham. <https://doi.org/10.1007/978-3-030-14524-8_11>. 2020.

SPROTTE, A. F. V. Determinação das curvas e dos parâmetros de células e módulos fotovoltaicos sob diversas condições de temperatura e de irradiância por meio de um modelo computacional. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica). Universidade Federal de Santa Catarina. Florianópolis. 2018.

STAUEMEYER, R. C. et al. **Understanding LSTM – a tutorial into Long Short-Term Memory Recurrent Neural Networks**. 23 set. 2019.

TIEPOLO, G. M.; PEREIRA, E. B.; URBANETZ JR, J.; PEREIRA, S. V.; GONÇALVES, A. R.; LIMA, F. J. L.; COSTA, R. S., ALVES, A. R. **Atlas de Energia Solar do Estado do Paraná**. 1a Edição. Curitiba: UTFPR, 2017.

VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**. Recife: 2006. Versão Digital, 443p.

VIANA, T. D. S. **Potencial de Geração de Energia Elétrica com Sistemas Fotovoltaicos com Concentrador no Brasil**. Programa de Pós-Graduação em Engenharia Civil. Universidade Federal de Santa Catarina, 2010.

WEATHER SPARK. **Dados meteorológicos**. Disponível em: <<https://pt.weatherspark.com/>>. Acesso em: 24 mai. 2023.