

Sistema FIEB



PELO FUTURO DA INOVAÇÃO

CENTRO UNIVERSITÁRIO SENAI CIMATEC
Programa de Pós-Graduação em
Modelagem Computacional e Tecnologia Industrial

HUGO EVERALDO SALVADOR BEZERRA

**CLASSIFICAÇÃO DE FALTAS EM PLANTAS
FOTOVOLTAICAS COM APLICAÇÃO DE INTELIGÊNCIA
ARTIFICIAL**

Salvador

2024

HUGO EVERALDO SALVADOR BEZERRA

**CLASSIFICAÇÃO DE FALTAS EM PLANTAS
FOTOVOLTAICAS COM APLICAÇÃO DE INTELIGÊNCIA
ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial do Centro Universitário SENAI CIMATEC como requisito parcial para a obtenção do título de Mestre em Modelagem Computacional e Tecnologia Industrial.

Orientador: Prof. Dr. Hugo Saba Pereira Cardoso.

Coorientador: Prof. Dr. Aloísio Santos Nascimento Filho.

Salvador

2024

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

B574c Bezerra, Hugo Everaldo Salvador

Classificação de faltas em plantas fotovoltaicas com aplicação de inteligência artificial / Hugo Everaldo Salvador Bezerra. – Salvador, 2024.

78 f. : il. color.

Orientador: Prof. Dr. Hugo Saba Pereira Cardoso.

Coorientador: Prof. Dr. Aloisio Santos Nascimento Filho.

Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2024.

Inclui referências.

1. Perceptron multicamadas. 2. Modelagem fotovoltaica. 3. Geração fotovoltaica. 4. Classificação de faltas. I. Centro Universitário SENAI CIMATEC. II. Cardoso, Hugo Saba Pereira. III. Nascimento Filho, Aloisio Santos. IV. Título.

CDD 006.3

CENTRO UNIVERSITÁRIO SENAI CIMATEC

Mestrado Acadêmico em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, aprova a Defesa de Mestrado, intitulada “**Classificação de Faltas em Plantas Fotovoltaicas com Aplicação de Inteligência Artificial**” apresentada no dia 06 de maio de 2024, como parte dos requisitos necessários para a obtenção do Título de Mestre em Modelagem Computacional e Tecnologia Industrial.

Orientador: **Prof. Dr. Hugo Saba Pereira Cardoso**
SENAI CIMATEC

Coorientador: **Prof. Dr. Aloisio Santos Nascimento Filho**
FIEB

Membro Interno: **Prof.^a Dr.^a Camila de Sousa Pereira-Guizzo**
SENAI CIMATEC

Membro Externo: **Prof. Dr. Alcides Codeceira Neto**
UPE

*Dedico este trabalho à minha esposa
Emília e filhos Gabriel e Ana Clara pelo
apoio, compreensão e paciência.*

AGRADECIMENTOS

Agradeço ao orientador Prof. Dr. Hugo Saba Pereira Cardoso e coorientador Prof. Dr. Aloísio Santos Nascimento Filho por todo apoio e orientação, ao Prof. Dr. Helon David de Macêdo Braz, Msc. Andre Luiz Pereira da Cruz e Msc. Alex Coutinho Pereira pelas conversas que me inspiraram na produção deste trabalho e à Profa. Dra. Camila de Sousa Pereira-Guzzo e Prof. Dr. Alcides Codeceira Neto pelas importantes contribuições para uma melhor estrutura e qualidade do trabalho final desta dissertação.

RESUMO

A geração fotovoltaica vem se mostrando uma alternativa de geração de energia importante entre as fontes renováveis, com flexibilidade para aplicações que vão da microgeração até grandes plantas fotovoltaicas, atuando como fonte complementar estrategicamente importante para grandes sistemas elétricos. Contudo este tipo de geração traz um desafio para detecção de falhas com utilização de sistemas de proteção e classificação convencionais. Uma alternativa para lidar com esse desafio é a utilização de técnicas de inteligência artificial para classificação de faltas, atingindo benefícios quanto à longevidade do sistema e otimização da manutenção. Foram abordadas falhas comuns em sistemas fotovoltaicos, a modelagem para a implantação de modelos computacionais e a aplicação de redes neurais do tipo perceptron de multicamadas para a classificação de falhas. Durante os estudos, realizaram-se testes para a definição de hiperparâmetros da rede neural, utilizando técnicas de otimização bayesiana e busca randômica e efetuaram-se comparações de resultados com base na acurácia. Os resultados obtidos contribuem para a compreensão e aprimoramento da detecção de falhas em sistemas fotovoltaicos por meio da aplicação eficaz de redes neurais.

Palavras-chave: perceptron multicamadas; modelagem fotovoltaica; geração fotovoltaica; classificação de faltas.

ABSTRACT

Photovoltaic generation has proven to be a significant alternative in the realm of renewable energy sources, offering flexibility for application in residential settings as well as large-scale photovoltaic plants, serving as a strategically important complementary source for extensive electrical systems. However, this form of generation poses a challenge for fault detection using conventional protection and classification systems. An alternative approach to address this challenge involves the application of Artificial Intelligence techniques for fault classification, yielding benefits in terms of system longevity and maintenance optimization. Common faults in photovoltaic systems were addressed, along with modeling for the implementation of computational models and the application of multilayer perceptron neural networks for fault classification. During the studies, tests were conducted to define the neural network hyperparameters using bayesian optimization and random search techniques, and comparisons of results were made based on accuracy. The obtained results contribute to the understanding and improvement of fault detection in photovoltaic systems through the effective application of neural networks.

Keywords: multilayer perceptron; photovoltaic modeling photovoltaic generation; fault classification.

LISTA DE FIGURAS

Figura 1 - Potência instalada por tipo de usina no nordeste brasileiro entre 2009 e dezembro de 2023	21
Figura 2 – Exemplo de rede neural perceptron de multicamadas	24
Figura 3 – Metodologia da pesquisa.....	28
Figura 4 – Visão do painel fotovoltaico	30
Figura 5 – Componentes de geração Fotovoltaicos	32
Figura 6 – Curvas I-V da placa CS6U em relação à irradiação e temperatura.....	33
Figura 7 – Curvas P-V da placa CS6U	34
Figura 8 - Circuito equivalente de modelo PV com um diodo	36
Figura 9 - Fluxograma de Algoritmo de cálculo de parâmetros de PV.....	37
Figura 10 - Curvas I-V e P-V dos modelos calculados e do programa de modelagem	41
Figura 11 – Classificação de faltas em matriz fotovoltaica	43
Figura 12 – Gráficos I-V com pontos de falha e operação normal	48
Figura 13 – Gráfico de funções de ativação.....	50
Figura 14 – Matriz Confusão do Modelo 1	58
Figura 15 – Matriz Confusão do Modelo 2	60

LISTA DE TABELAS

Tabela 1. Comparativo de características de rede perceptron de multicamadas	25
Tabela 2. Parâmetros calculados para MAXPOWER CS6U-330P.....	40
Tabela 3. Configuração de hiperparâmetros para <i>tuning</i>	55
Tabela 4. Hiperparâmetros do Modelo 1 - Otimização Bayesiana.	56
Tabela 5. Precisão e Revocação dos resultados do Modelo 1	57
Tabela 6. Hiperparâmetros do Modelo 2 – Busca Randômica.	59
Tabela 7. Precisão e Revocação dos resultados do Modelo 2.....	59

LISTA DE SIGLAS E ABREVIATURAS

ADAM	<i>Adaptive Moment Estimation</i>
ANEEL	Agência Nacional de Energia Elétrica
EPE	Empresa de Pesquisa Energética
IRENA	<i>International Renewable Energy Agency</i>
KNN	<i>K nearest neighbor</i>
MLP	<i>Multilayer Perceptron</i>
MME	Ministério de Minas e Energia
MMGD	Micro e Mini Geração Distribuída
MPPT	<i>Maximum Power Point Tracking</i>
NADAM	<i>Nesterov-accelerated Adaptive Moment Estimation</i>
ONS	Operador Nacional do Sistema Elétrico
RBF	<i>Radial Basis Function</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Redes Neurais Artificiais
SGD	<i>Stochastic Gradient Descent</i>
SIN	Sistema Interligado Nacional
STC	<i>Standard Teste Condition</i>
SVM	<i>Support Vector Machines</i>

LISTA DE SÍMBOLOS

a	Fator de idealidade do diodo
G	Irradiância incidente na célula (W/m^2)
G_n	Irradiância padrão da célula ($1000\text{W}/\text{m}^2$)
I	Corrente da célula fotovoltaica (A)
I_0	Corrente de saturação reversa do diodo (A)
I_{pv}	Fotocorrente gerada pela célula fotovoltaica (A)
I_{sc}	Corrente de curto-circuito da célula (A)
k	Constante de Boltzman ($k = 1,38 \cdot 10^{-23} \text{ J/K}$)
NOCT	Temperatura de operação da célula ($^{\circ}\text{C}$)
T_n	Temperatura da célula em condições padrão de teste (298K)
q	Carga de um elétron ($q = 1,6 \cdot 10^{-19} \text{ C}$)
V_{oc}	Tensão de circuito aberto (V)

SUMÁRIO

1	INTRODUÇÃO	17
1.1	OBJETIVOS	19
1.1.1	<i>Objetivo Geral</i>	19
1.1.2	<i>Objetivos Específicos</i>	19
1.2	ORGANIZAÇÃO DO DOCUMENTO	20
2	REVISÃO DA LITERATURA	21
3	MATERIAIS E MÉTODOS	28
4	PAINÉIS FOTOVOLTAICOS, TIPO DE FALTAS E REDES NEURAIS PARA CLASSIFICAÇÃO DE FALTAS	32
4.1	CARACTERÍSTICAS E MODELAGEM EM PAINÉIS FOTOVOLTAICOS	32
4.2	MODELAGEM DE PAINÉIS FOTOVOLTAICOS	35
4.3	FALTAS EM PAINÉIS FOTOVOLTAICOS	41
5	OTIMIZAÇÃO E APLICAÇÃO DA ARQUITETURA DO MODELO PERCEPTRON DE MULTICAMADAS NA CLASSIFICAÇÃO DE FALTAS DE FOTOVOLTAICAS ...	45
6	CONCLUSÕES	63
6.1	SUGESTÕES PARA TRABALHOS FUTUROS	63
	REFERÊNCIAS	65
	ANEXOS	69
	PRODUÇÃO TÉCNICA E CIENTÍFICA.....	70

1 INTRODUÇÃO

Historicamente a matriz energética brasileira é prioritariamente alimentada por energia proveniente de reservatórios de rios, onde são construídas grandes usinas hidráulicas. Depois da crise energética de 2001, caracterizada por disponibilização insuficiente de geração de energia elétrica, iniciaram de forma mais ampla as discussões sobre necessidade de diversificação da matriz energética brasileira para atendimento da demanda. Em 2009 iniciaram realização de leilões de concessão pelo órgão regulador do setor elétrico brasileiro, a Agência Nacional de Energia Elétrica (ANEEL), específicos para instalação de plantas de energias renováveis (Brasil, 2024).

A geração fotovoltaica vem se mostrando uma alternativa de geração de energia importante entre as fontes renováveis, atraindo valor global estimado de 298 milhões de dólares, correspondente a 60% do investimento global em energia renovável (IRENA, 2023). Somente no ano de 2021, houve uma adição de potência instalada de 138 GW no mundo utilizando esta tecnologia (IRENA, 2023).

Trata-se de um tipo de geração de energia limpa que pode ser aplicada como microgerações (até 75 kW de potência gerada), minigeração (até 5 MW de potência gerada) ou grandes centrais fotovoltaicas, dando flexibilidade para sua aplicação desde alimentação destinadas a casas residenciais ou de veraneio, até fonte complementar estrategicamente importante para grandes sistemas como o Sistema Interligado Nacional do Brasil (SIN) (Brasil; Agência Nacional de Energia Elétrica, 2023).

A presença cada vez maior de geração de energias renováveis dos sistemas elétricos vêm sendo um desafio, não só para estabilidade e operação dos sistemas elétricos, mas também para as proteções convencionais devido à utilização massiva de eletrônica de potência, por meio de tiristores, com comportamento e características eletricamente atípicas, sendo necessária implementação de esquemas especiais de proteção (Brasil; Empresa de Pesquisa Energética; Ministério de Minas e Energia, 2020).

Técnicas de aprendizado de máquina vêm sendo utilizadas em diversas áreas de aplicação, assim como o estudo de sua aplicação na área de sistemas elétricos para análise e diagnósticos de falhas, em sistemas de geração fotovoltaicos (Vieira, 2021). Com a tecnologia disponível atualmente, técnicas de aprendizado de máquina

podem ser aplicadas em gerações fotovoltaicas desde pequeno porte, até grandes parques de geração (Chine *et al.*, 2016).

No início da década de 1940 os primeiros computadores elétricos estavam sendo construídos e já nesta época as redes neurais artificiais (RNA) estavam sendo concebidas. Um dos primeiros trabalhos reconhecido na área de Inteligência Artificial foi “*A logical calculus of the ideas immanent in nervous activity*”, produzido por Warren McCulloch e Walter Pitts em 1943. O trabalho se inspirava no sistema neural para realizar cálculos com implementação de expressões lógicas (McCulloch; Pitts, 1943).

Na década seguinte os princípios do perceptron foram definidos no Cornell Aeronautical Laboratory por Frank Rosenblatt, no artigo *The perceptron: A probabilistic model for information storage and organization in the brain*. O perceptron é uma arquitetura simples de RNA, representando um neurônio artificial que trabalha não só com lógica digital, mas também para calcular dados de entradas e saídas em números reais (Rosenblatt, 1958).

Para resolver alguns problemas de aplicação da rede perceptron, como classificações não lineares e problemas com lógica de ou exclusivo (XOR), foi proposta, na década de 1960, a RNA conhecida como perceptron de multicamadas, usualmente definida como MLP (do inglês *Multilayer Perceptron*). A MLP foi popularizada na década de 1980 com o aumento da capacidade de processamento dos computadores e com a apresentação do algoritmo de retro programação (Rumelhart; Hinton; Williams, 1985). A técnica de treinamento da MLP conhecida como retropropagação (em inglês *back-propagation*) foi popularizada através do livro *Parallel Distributed Processing* publicado em 1986 por Rumelhart and McClelland.

Várias técnicas de detecção de falhas são utilizadas em painéis fotovoltaicos, entre elas caracterização e falha por parâmetros elétricos, processamento de sinais, termografia infravermelha e técnicas híbridas. Técnicas de aprendizado de máquina também estão sendo utilizadas para este fim como redes neurais probabilísticas, redes neurais bayesianas, árvore de decisão, *K nearest neighbor* (KNN), *support vector machines* (SVM) e perceptron de multicamadas. (Ghaffarzadeh; Azadian, 2019)

As redes MLP são aplicadas em várias áreas como reconhecimento de padrões, voz e classificação. Na pesquisa, é realizada classificação de falhas elétricas em sistema fotovoltaico em operação por meio de uma rede neural perceptron de multicamadas. Foram aplicadas técnicas de otimização de hiperparâmetros,

mostrando a importância de sua utilização no processo de definição de modelos de redes neurais. Para atingir esse objetivo, foram delineadas diversas tarefas específicas. Como passos específicos, foram caracterizadas as falhas comuns encontradas em plantas fotovoltaicas, calculada a modelagem de células fotovoltaicas, definida uma técnica de otimização apropriada para a estimação de hiperparâmetros de redes neurais artificiais destinadas à classificação de falhas em sistemas fotovoltaicos, aplicado o modelo perceptron de multicamadas com hiperparâmetros otimizados e, por fim, avaliado o desempenho do modelo proposto na classificação de falhas em sistemas fotovoltaicos através da acurácia das classificações.

A pesquisa abrange desde a identificação das falhas elétricas até a implementação e avaliação de um modelo de rede neural, com ênfase na otimização dos hiperparâmetros para aprimorar a eficácia na classificação de falhas em sistemas fotovoltaicos.

1.1 Objetivos

O problema de pesquisa tem como ênfase definir em que medida utilizar técnicas de escolha de hiperparâmetros de redes neurais consegue melhorar a acurácia das classificações de faltas em sistemas fotovoltaicos.

1.1.1 Objetivo Geral

Avaliar a importância da utilização de técnicas de otimização na definição de hiperparâmetros de redes neurais artificiais para aplicação na classificação de faltas elétricas em sistema fotovoltaico em operação.

1.1.2 Objetivos Específicos

Estudo e aplicação de modelo de perceptron de multicamadas com treinamento e verificação de acurácia de classificação de faltas em sistema fotovoltaico em operação. Como objetivos específicos são listados:

- Caracterizar faltas comuns em plantas fotovoltaicas;
- Cálculo de modelagem de células fotovoltaicas;
- Avaliar desempenho de modelos de redes neurais perceptron de multicamadas, utilizando técnica de definição de hiperparâmetros, para

classificação de faltas em sistemas fotovoltaicos.

1.2 Organização do Documento

Nesta seção constam os capítulos e breve descrição dos assuntos tratados em cada um deles:

- Capítulo 2 – apresenta revisão da literatura referente à falta e modelagem de painéis fotovoltaicos, além de seleção de arquitetura de redes neurais do tipo perceptron de multicamadas para classificação de faltas em sistemas fotovoltaicos;
- Capítulo 3 – descrição da metodologia e ferramentas utilizadas na pesquisa;
- Capítulo 4 – aborda modelagem de células fotovoltaicas e tipos de faltas em sistemas fotovoltaicos;
- Capítulo 5 – aplicação de métodos de otimização na definição de hiperparâmetros de arquitetura de rede neural perceptron multicamadas, treinamento e classificação de faltas em sistema fotovoltaico;
- Capítulo 6 – são apresentadas conclusões do trabalho e sugestões de trabalhos futuros.

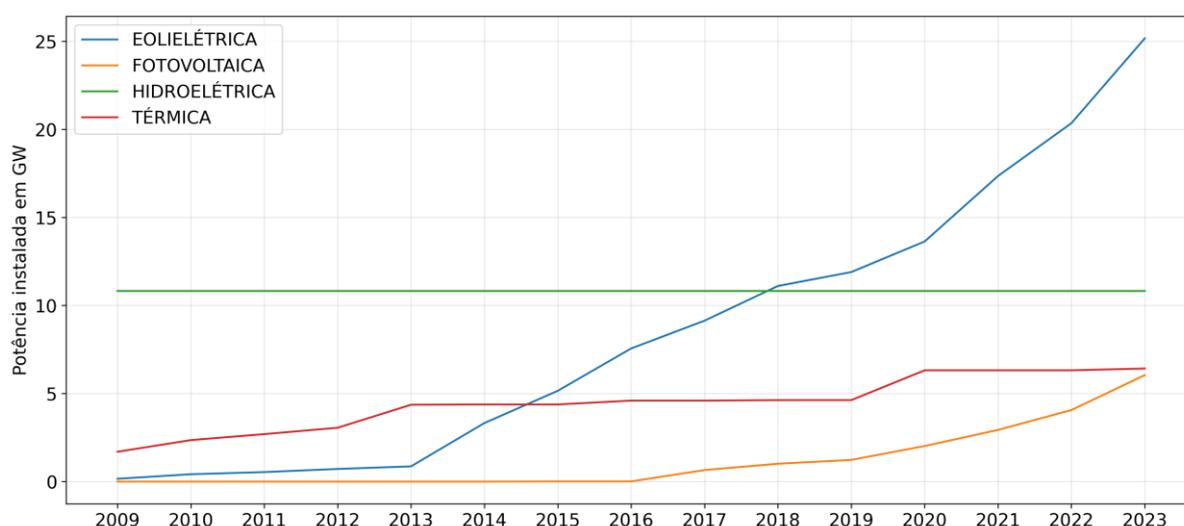
2 REVISÃO DA LITERATURA

Neste capítulo é realizada revisão de literatura referente à modelagem e faltas em sistemas fotovoltaicos, além de revisão sobre seleção de hiperparâmetros para redes neurais artificiais.

A geração fotovoltaica no Brasil vem ganhando importância, correspondendo em novembro de 2023 a 5,7% de toda capacidade instalada no SIN, com perspectiva de alcançar 7,0% até 2026 (ONS, 2022). A Micro e Minigeração Distribuída (MMGD) correspondia em 2021 a 4% da capacidade instalada e contratada do SIN e tem projeção de chegar a 17% em 2031, dos quais 91,3% sendo de geração fotovoltaica (Brasil; Ministério de Minas e Energia; Empresa de Pesquisa Energética, 2022).

O grande potencial fotovoltaico hoje está no nordeste brasileiro. A Figura 1 mostra, com fonte de dados abertos, sobre a capacidade instalada de geração disponibilizada no Portal de Dados Abertos do ONS com números das usinas despachadas pelo Operador Nacional do Sistema Elétrico. Constata-se que desde 2018 as usinas que têm como fonte primária energia eólica têm maior potência instalada, não sendo mais as usinas hidráulicas a principal fonte de energia elétrica na matriz energética no nordeste brasileiro. O gráfico também deixa claro que a partir de 2016 as usinas que funcionam baseadas em energia fotovoltaica vêm crescendo de forma consistente no Nordeste (ONS, 2024).

Figura 1 - Potência instalada por tipo de usina no nordeste brasileiro entre 2009 e dezembro de 2023



Fonte: Dados de (ONS, 2024), Autoria Própria

São diversos os tipos de modelos que podem ser utilizados para representação de painéis fotovoltaicos, como modelo explícito, modelo de quatro parâmetros, modelo de cinco parâmetros (ou de um diodo) e modelo exponencial (ou de dois diodos) (Benghanem; Alamri, 2009).

Em Villalva, Gazoli e Filho (2009) é definida metodologia de cálculo para modelagem de parâmetros para modelo de um diodo, também definido como modelo de cinco parâmetros.

Também é utilizado modelo de um diodo em Mohapatra, Nayak e Mohanty (2013) adaptando o método de Villalva, Gazoli e Filho (2009), porém aplicando cálculo de parâmetros utilizando técnica *trust-region-doleg*. O método de cálculo de Mohapatra, Nayak e Mohanty (2013) será explanado com mais detalhe no item 4.2, Modelagem de painéis fotovoltaicos.

Além da modelagem do painel fotovoltaico para a estimativa da resposta dinâmica do ponto de vista elétrico, o conhecimento das diferentes classes de falhas que podem afetar o sistema é importante. A classificação precisa das falhas auxilia na identificação da causa do problema e na otimização das estratégias de reparo e manutenção.

A classificação de faltas em sistemas fotovoltaicos pode ser abordada por meio de diferentes formas de agrupamento. Autores como Chouay e Ouassaid (2017) concentram maior atenção em localização das falhas do que suas causas, delimitando os locais potenciais de falhas, como células fotovoltaicas, módulos ou painéis, e falhas que afetam o *string* de painéis.

Enquanto Djalab et al. (2020) também subdividem os locais de falhas nas células, módulos, *strings* e *arrays*, eles aprofundam a discussão sobre as causas das falhas, considerando tipos específicos de falhas, componentes afetados, causas e efeitos.

Ghaffarzadeh e Azadian (2019) abordam falhas no lado do sistema de corrente contínua (antes do inversor) e no sistema de corrente alternada (inversor e rede de potência). Nesse mesmo estudo, as falhas são caracterizadas como permanentes ou temporárias e são classificadas perdas de características constantes e variáveis por Chine et al. (2016).

No trabalho de Lazzaretti et al. (2020), são mencionadas falhas em corrente alternada e corrente contínua como duas grandes categorias, sendo que há uma

maior diversidade de tipos de falhas em corrente contínua.

Em Sabri, Tlemçani e Chouder (2019), são consideradas falhas no sistema de bateria, parte integrante do sistema fotovoltaico. Apesar de ser um sistema de corrente contínua, não está diretamente conectado ao conjunto de strings de módulos fotovoltaicos.

Classificações mais escalonadas são encontradas em Basnet, Chun e Bang (2020) e em Vieira (2021). Basnet, Chun e Bang, (2020) separam em três grandes grupos de faltas de origem físicas, elétricas e ambientais enquanto Vieira coloca como troncos principais *Mismatches*, diodo de *by-pass*, desconexão de módulos/*strings*, faltas assimétricas, arcos elétricos, descargas atmosféricas e faltas de aterramento.

Momentos que podem ocorrer as faltas também são abordados, salientando que as faltas podem ser provenientes de fatos ocorridos ainda antes do sistema fotovoltaico entrar em operação, como durante a fabricação dos módulos ou durante sua instalação (Bharath; Haque; Khan, 2018).

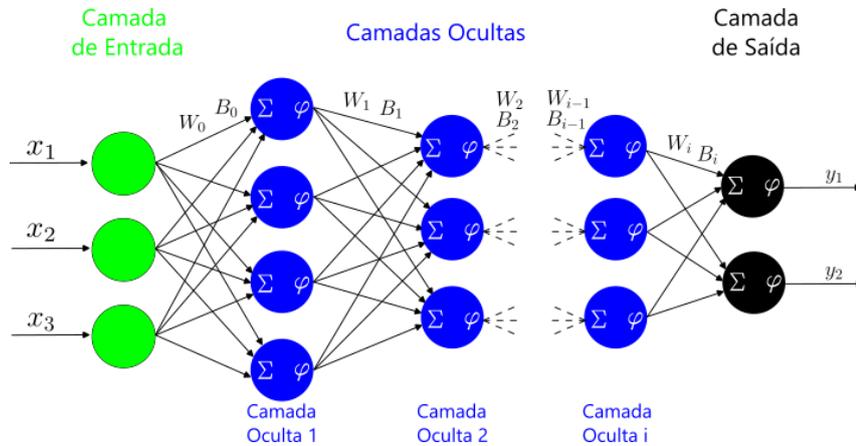
Uma das ferramentas que pode ser utilizada para a classificação de falhas em sistemas fotovoltaicos são redes neurais artificiais.

As perceptron de multicamadas são caracterizadas em Haykin (2009) como sendo redes neurais artificiais com uma ou mais camadas ocultas sequenciais, com alto nível de conectividade dos neurônios (cada neurônio da camada predecessora se conectando a cada neurônio da camada sucessora) e utilização de função de ativação não linear e diferenciável.

Em literaturas publicadas posteriormente como em Géron (2022) encontra-se uma mudança quanto à função de ativação, que apesar de reforçar a importância da característica não linear, não aplica apenas funções deriváveis.

As redes perceptron de multicamadas também são definidas como redes *neurais feedforward* ou *deep feedforward* e são consideradas modelos essenciais de aprendizado profundo. Esses modelos são chamados de *feedforward* porque a informação flui da camada de entrada a partir de entrada X , passando pelos cálculos intermediários das camadas ocultas e chegando à saída Y (Goodfellow; Bengio; Courville, 2016).

Figura 2 – Exemplo de rede neural perceptron de multicamadas



Fonte: Autoria Própria

Um exemplo de rede neural artificial do tipo perceptron de multicamadas é representado na Figura 2. Nesta rede tem-se a matriz de variáveis de entrada X , neste caso formada por x_1 , x_2 e x_3 , conectada à camada de entrada. As variáveis de saída y_1 e y_2 formando a matriz Y que são calculadas pela camada de saída. Podem existir tantas variáveis de entradas e saídas quantas forem necessárias. As camadas de entrada e saída terão a mesma quantidade de neurônios da quantidade de variáveis de entrada e variáveis de saída, respectivamente. As camadas ocultas ficam entre as camadas de entrada e saída e podem ter quantos neurônios forem definidos pela aplicação. São utilizadas matrizes de peso W e vetor de vieses B , calculados durante fase de treinamento, e função de ativação φ para cálculo de valores a serem passados da camada anterior para a seguinte. A matriz W e o vetor B são formados por parâmetros da rede neural.

Treinar um modelo significa executar um algoritmo para encontrar os parâmetros do modelo que o farão se ajustar melhor aos dados de treinamento e, idealmente, realizar boas previsões em novos dados (Géron, 2022).

O cálculo do resultado da saída de cada camada pode ser representado pela função de hipótese h , com aplicação da função de ativação φ na soma dos vetores B e vetor resultante do produto do vetor de entrada X e da matriz de peso W , conforme a equação (1) :

$$h_{W,B}(X) = \varphi(XW + B) \quad (1)$$

No contexto da pesquisa, a acurácia refere-se a uma medida de desempenho utilizada em tarefas de classificação em aprendizado de máquina. É uma métrica fundamental que avalia a correção geral das previsões do modelo, indicando a proporção de instâncias corretamente identificadas pelo sistema em relação ao total de instâncias avaliadas (Géron, 2022). A acurácia é a proporção de exemplos para os quais o modelo produz a saída correta em relação ao total de instâncias previstas (Goodfellow; Bengio; Courville, 2016).

Pesquisas têm estudado aplicação de RNA para detecção e classificação de faltas em sistemas fotovoltaicos, apresentando análises comparativas do desempenho das redes MLP em relação a outras técnicas, como RBF, KNN, árvore de decisão e SVM, demonstrando a superioridade das redes MLP em termos de acurácia na classificação de falhas.

Apesar da variedade de características das MLP aplicadas nos trabalhos, todas as aplicações atingiram acurácia entre 90,3% e 100% para detecção de faltas em placas fotovoltaicas, como pode-se ver no resumo que consta na Tabela 1.

Tabela 1. Comparativo de características de rede perceptron de multicamadas

Trabalho	Camadas Ocultas	Nº Neurônios em cada camada	Função de ativação	Acurácia
(Chine <i>et al.</i> , 2016)	2	13	Sigmoidal	90,3%
(Chouay; Ouassaid, 2017)	1	40	Sigmoidal	94,1%
(Bharath; Haque; Khan, 2018)	1	12	Não Informado	98,2%
(Sabri; Tlemçani; Chouder, 2019)	1	25	Sigmoidal	97,7%
(Rao; Spanias; Tepedelenlioglu, 2019)	3	6	tanh	99,7%
(Da Costa <i>et al.</i> , 2019)	1	33	Não Informado	99,65%
(Lazzaretti <i>et al.</i> , 2020)	1	21	ReLU	95,44%
(Basnet; Chun; Bang, 2020)	3	8	ReLU	100%
(Djalab <i>et al.</i> , 2020)	1	10	Sigmoidal	94,0%
(Vieira, 2021)	1	35	tanh	99,1%

Fonte: Adaptado de (Bezerra *et al.*, 2023).

Trabalhos como Chine *et al.* (2016) e Bharath, Haque e Khan (2018) realizam comparação de aplicação de rede MLP e outros tipos de rede como *Radial Basis Function* (RBF) para classificação de falhas em painéis fotovoltaicos, obtendo resultados mais precisos com as redes MLP. Em Chine *et al.* (2016) a acurácia registrada pela rede MLP foi de 90,3% na classificação de faltas enquanto a RBF conseguiu precisão de 68,4%. Em Bharath, Haque e Khan (2018) o modelo MLP teve acurácia de 98,20% enquanto a RBF 93,55%.

O mesmo ocorre em Da Costa *et al.* (2019) e Lazzaretti *et al.* (2020) que comparam MLP com as técnicas *K-Nearest Neighbors* (KNN), *Árvore de Decisão* e *Support Vector Machines* (SVM). Em Lazzaretti *et al.* (2020) os números de acurácia para a classificação com a base de teste foram 95,44% utilizando MLP, 94,59% utilizando SVM, 89,96% com classificação KNN e 70,85% com *Árvore de Decisão*.

Já em Da Costa *et al.* (2019) a MLP atingiu acurácia de 99,65% contra 98,64% com SVM, 89,92% com *Árvore de Decisão*, e 82,50% com KNN. O tempo de treinamento também traz grandes discrepâncias, mas desta vez com desvantagem para MLP onde foram necessários 205,26 segundos enquanto a SVM necessitou de 15,58 segundos, a *Árvore de Decisão* 0,75 segundos, e KNN 0,71 segundos.

Referente à quantidade de camadas ocultas, trabalhos como Chouay; Ouassaid (2017), Sabri, Tlemçani e Chouder (2019), Djalab *et al.* (2020) e Vieira (2021) utilizam apenas uma camada oculta variando entre 10 e 40 neurônios. Outros trabalhos também usam apenas uma camada oculta e deixam claro que aplicaram técnicas realizando muitos treinamentos variando a quantidade de neurônio na camada, selecionando o modelo que atingiu melhor acurácia

Outros trabalhos utilizam mais de uma camada oculta como em Chine *et al.* (2016) que utiliza uma rede MLP com duas camadas ocultas compostas de 13 neurônios cada camada.

Em Rao, Spanias e Tepedelenlioglu (2019) foram considerados modelos MLP de três camadas com 6 neurônios em cada camada e em Basnet, Chun e Bang (2020) são utilizadas também três camadas com 8 neurônios em cada camada.

Os modelos estudados com duas ou três camadas ocultas sempre utilizam a mesma quantidade de neurônios por camada. Em Maiorov e Pinkus (1999) é colocado que para um modelo de rede neural de duas camadas deve-se utilização $2d + 1$ neurônios na primeira camada e $4d + 3$ neurônios na segunda camada, sendo d o

número de variáveis de entrada.

As funções de ativação φ também variam nos trabalhos citados. As funções mais comumente utilizadas são do tipo sigmoideal, tangente hiperbólica (\tanh) e em trabalhos mais recentes a função *Rectified Linear Unit* (ReLU). Porém não se tem registro do motivo da preferência por uma ou outra função de ativação da configuração de número de camadas e neurônios.

Um hiperparâmetro é definido em Géron (2022) como sendo parâmetros de um algoritmo de aprendizado e não do modelo, sendo definidos antes do treinamento da rede neural e permanecendo constante durante todo treinamento. São exemplos de hiperparâmetros quantidade de camadas, número de neurônios por camada, função de ativação, método de regularização e técnica de otimização usada no cálculo dos pesos e vieses.

Em Bergstr e Bengio (2012) é proposta a *Random Search* (Busca Aleatória) como substituto e linha de base que seja razoavelmente eficiente e mantendo as vantagens da simplicidade de implementação e reprodutibilidade da pesquisa em grade pura.

Em Snoek, Larochelle e Adams (2012) é colocado como alternativa a *Bayesian Optimization* (Otimização Bayesiana) para obtenção de processo de *tuning* robusto com utilização de processamento paralelo.

Além das características e hiperparâmetros discutidos, técnicas como regularização também são importantes para evitar desempenho inadequado da rede neural. Kukačka, Golkov e Cremers (2017) definem regularização como “qualquer técnica adicional que visa fazer com que o modelo generalize melhor, ou seja, produza melhores resultados no conjunto de teste” e lista 58 métodos diferentes de regularização.

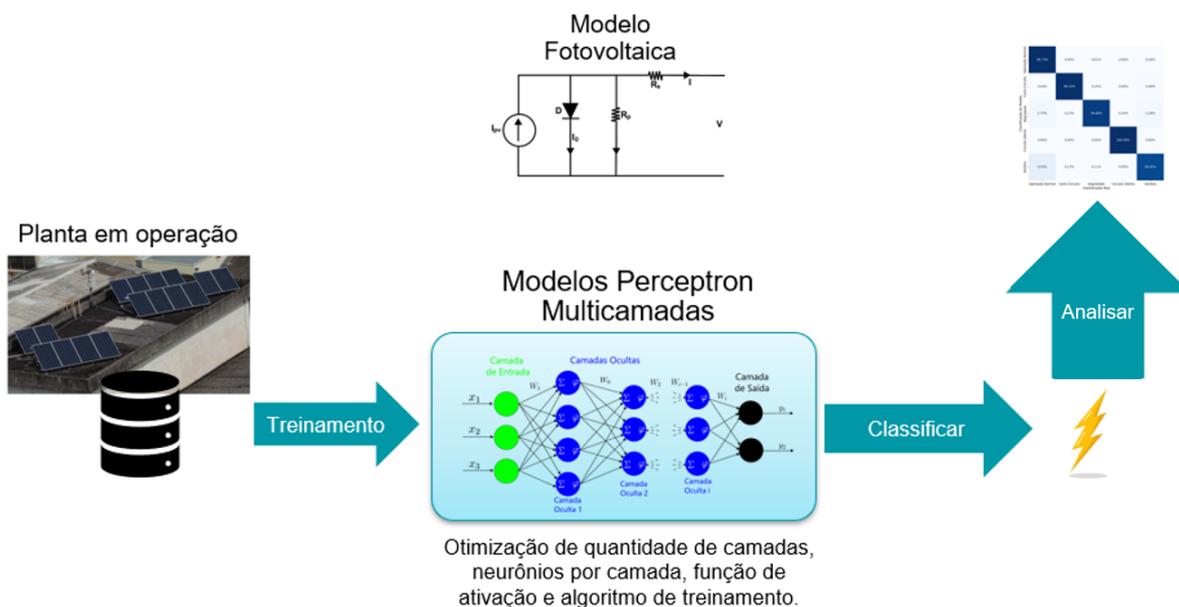
O levantamento realizado servirá de base para definição dos hiperparâmetros a serem definidos para os testes. Sem um levantamento prévio para definição dos limites inferiores e superiores de número de camadas, neurônios por camada, técnica de treinamento e função de ativação, ou seria necessário um trabalho computacional muito grande para treinar e testar muitos modelos de redes ou haveria o risco de se definir um subconjunto de características onde a melhor arquitetura não estaria contemplada.

3 MATERIAIS E MÉTODOS

Neste trabalho é abordada a condição de faltas em corrente contínua do sistema fotovoltaico com base na medição de grandezas elétricas processadas por rede neural perceptron de multicamadas. Estas condições dão base ao estudo da definição dos hiperparâmetros utilizados na rede perceptron de multicamadas utilizando duas técnicas de escolha de hiperparâmetros, busca randômica e otimização bayesiana, baseando em teste de várias redes neurais e realização de escolha dos hiperparâmetros por meio das acurácias das classificações de cada rede.

O problema deve ser entendido com suas características gerais e quais os desafios encontrados para sua solução. No trabalho são discutidos tipos de faltas e modelagens de sistemas fotovoltaicos com intuito de entender o problema a ser resolvido, como a técnica de classificação deve ser aplicada e quais as vantagens que a implantação de um sistema de classificação de faltas pode entregar.

Figura 3 – Metodologia da pesquisa



Fonte: Autoria Própria

Para definir qual tipo de técnica de aprendizado de máquina é mais adequado para solução do problema proposto, foram considerados os trabalhos de Chine *et al.* (2016), Bharath, Haque e Khan (2018), Da Costa *et al.* (2019) e Lazzaretti *et al.* (2020) que fizeram comparação entre resultados de técnicas diferentes de aprendizado de

máquina para classificação de faltas e foi demonstrado que os melhores valores de acurácia sempre são alcançados pela perceptron de multicamadas.

Adicionalmente, trabalhos como Chouay e Ouassaid (2017), Sabri, Tlemçani e Chouder (2019), Rao, Spanias e Tepedelenlioglu (2019), Basnet, Chun e Bang (2020) e Djalab *et al.* (2020) selecionaram a rede perceptron de multicamadas como rede a ser aplicada para classificação de faltas em sistemas fotovoltaicos. Baseado nos trabalhos citados, a pesquisa aplicou a rede neural artificial perceptron de multicamadas para classificação de faltas em sistemas fotovoltaicos.

Com a técnica de aprendizado de máquina definida, houve a pesquisa de que hiperparâmetros da rede perceptron de multicamadas devem ser utilizados. As características definidas influenciam diretamente no desempenho do modelo referente ao tempo de treinamento, tempo de identificação da falta e acurácia.

Tradicionalmente a arquitetura das redes neurais são fixadas antes do treinamento, outros estudos propõem aprendizado construtivo, mas a maioria dos estudos não se preocupa em realizar otimização da estrutura da rede neural (Bergstra; Bengio, 2012).

Os trabalhos publicados entre 2013 e 2023 para classificação de faltas em sistemas fotovoltaicos utilizando ferramentas de aprendizado de máquina costumam abranger bem a problemática das faltas e caracterizar os problemas a serem tratados, porém explanam pouco sobre métodos e ferramentas de definição dos hiperparâmetros a serem utilizados.

Algoritmos de aprendizado de máquina frequentemente requerem uma sintonização cuidadosa de hiperparâmetros do modelo, termos de regularização e parâmetros de otimização. Infelizmente, essa sintonização muitas vezes é uma arte que exige experiência, regras práticas não documentadas ou, às vezes, uma busca exaustiva (Snoek; Larochelle; Adams, 2012).

O problema da otimização da arquitetura da rede neural é achar a quantidade ótima de camadas ocultas, quantidade de neurônios em cada uma destas camadas e a função de ativação adequada, no intuito de maximizar a performance da rede neural (Ettaouil; Lazaar; Ghanou, 2013).

A pesquisa aplica e compara resultados de redes neurais do tipo perceptron de multicamadas com arquiteturas definidas por meio de utilização de duas técnicas de definição de hiperparâmetros, busca aleatória e otimização bayesiana. Os dois modelos são treinados e realizam classificação das faltas utilizando base de dados

coletada de um sistema fotovoltaico em operação.

Considerando o usual empirismo de definição dos hiperparâmetros de rede neural verificado nos trabalhos citados na Tabela 1, do disposto em Bergstra e Bengio (2012) sobre a técnica de busca randômica e comparação com técnica de busca em grade, como também o disposto em Snoek, Larochelle e Adams (2012) sobre a técnica de otimização bayesiana, é plausível testar a hipótese que a utilização destas duas técnicas na definição de hiperparâmetros de redes neurais perceptron de multicamadas possa resultar em melhorias significativas na precisão de sistemas de classificação de faltas em sistemas fotovoltaicos.

A pesquisa visa testar essa hipótese por meio de experimentos e análises quantitativas, buscando contribuir para o avanço da área de inteligência artificial e suas aplicações práticas.

O modelo da rede perceptron de multicamadas foi treinado, validado e realizada classificação de falta para análise utilizando-se dados coletados em sistema fotovoltaico de 5 kWp de potência máxima, que está instalado na Universidade Federal Tecnológica do Paraná (latitude -25,438686 e longitude -49,268487) na cidade de Curitiba, estado do Paraná, utilizando módulos do modelo CS6U-330P do fabricante Canadian Solar. Na Figura 4 tem-se foto dos painéis fotovoltaicos instalados.

Figura 4 – Visão do painel fotovoltaico



Fonte: (Lazzaretti *et al.*, 2020)

O sistema é formado de dois *strings* independentes, cada um composto por oito

módulos em série, ligados a um inversor produzido pela fabricante NHS.

Características dos dados de entrada da rede neural como quantidade de variáveis de entrada (*features*), quantidade de registros, natureza dos dados (categóricos, boolianos, datas, números inteiros ou números contínuos) também podem influenciar na arquitetura mais adequada a ser adotada.

A base de dados utilizada conta com cinco colunas, com informação de tensão em corrente contínua V_{dc1} do *string 1*, tensão em corrente contínua V_{dc2} do *string 2*, corrente I_{dc1} do *string 1*, corrente I_{dc2} do *string 2* e coluna categórica informando a situação do sistema sendo 0 para operação normal, 1 para curto-circuito, 2 para sistema degradado, 3 para circuito aberto e 4 para módulo(s) com sombra (Lazzaretti *et al.*, 2020).

O presente estudo empregou a biblioteca SciPy (Pauli Virtanen *et al.*, 2020) para realizar o cálculo da modelagem do painel fotovoltaico utilizando técnica de otimização Nelder-Mead. Para o pré-processamento da base de dado foi adotada a biblioteca Pandas (McKinney *et al.*, 2010). A implementação da modelagem das redes neurais foram realizadas utilizando a biblioteca TensorFlow/Keras (Abadi, Martin *et al.*, 2016). Para tarefas adicionais, como o cálculo de métricas de resultados de classificação e a seleção randômica de dados, recorreu-se à biblioteca Scikit-learn (Pedregosa *et al.*, 2011). Todas as bibliotecas mencionadas são desenvolvidas para a linguagem de programação Python.

4 PAINÉIS FOTOVOLTAICOS, TIPO DE FALTAS E REDES NEURAIIS PARA CLASSIFICAÇÃO DE FALTAS

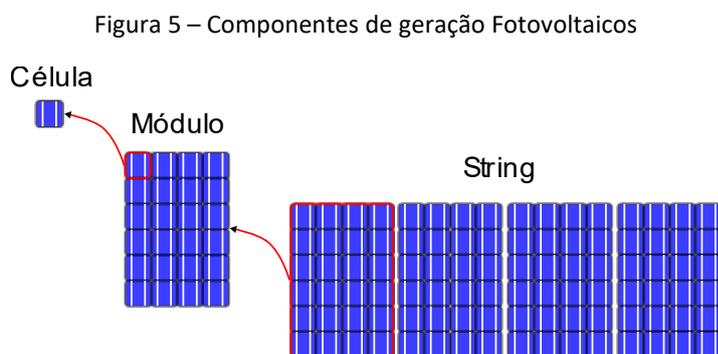
4.1 Características e modelagem em painéis fotovoltaicos

As células fotovoltaicas são a base da geração fotovoltaica. Essas células são compostas por materiais semicondutores, que possuem a propriedade de liberar elétrons quando expostos à irradiação solar. Quando a irradiação atinge a superfície dessas células, ela excita os elétrons presentes nos átomos do material semicondutor, gerando uma corrente contínua elétrica (Villalva; Gazoli, 2012).

Os painéis ou módulos são formados por células fotovoltaicas e projetados para capturar a maior quantidade possível de luz solar e convertê-la em eletricidade. Geralmente, eles são instalados em locais estratégicos, como telhados de edifícios ou em grandes campos solares, para maximizar a exposição à luz solar ao longo do dia (Villalva; Gazoli, 2012).

Os módulos podem ser ligados eletricamente em arranjos série e paralelos para formar um *string* de módulos fotovoltaicos. Estes *strings* são ligados a inversores que transformam a corrente contínua gerada em corrente alternada para alimentação de cargas ou interligação com um sistema elétrico. Também é possível haver baterias neste sistema para armazenar energia em momentos que o sistema estiver gerando mais que a demanda do sistema e fornecer energia quando a demanda for maior que a energia gerada (Villalva; Gazoli, 2012).

Os *strings* dos sistemas fotovoltaicos são formados por ligações elétricas série e paralelas de painéis ou módulos, que por sua vez são compostos por um conjunto de células fotovoltaicas, conforme representação esboçada na Figura 5.

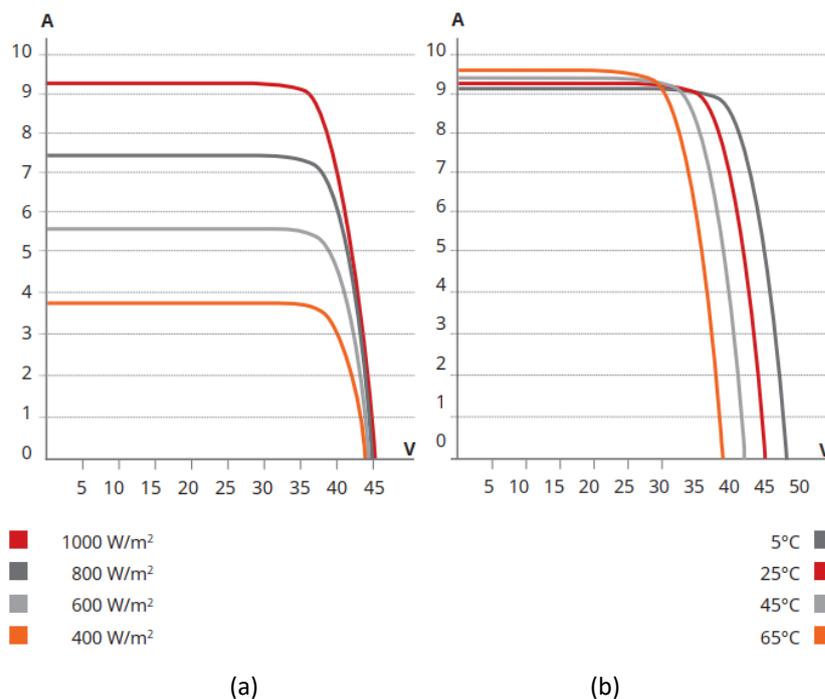


Fonte: Autoria Própria

As placas fotovoltaicas têm comportamento elétrico tipicamente representado por meio de curva característica I-V (relação entre corrente e tensão) e P-V (relação potência e tensão (Vieira, 2021). Como exemplo tem-se a curva I-V na Figura 6 (a) e (b) do painel CS6U da fabricante Canadian Solar, que serão utilizadas nesta pesquisa.

Na Figura 6 (a) pode-se verificar relação I-V e como a geração se comporta com a variação da irradiância mantendo a temperatura em condições normais de teste de 25°C, ou comumente referido como STC (do inglês *Standard Teste Condition*). Conforme é esperado, com o aumento da irradiância verifica-se um aumento da corrente em relação à tensão, caracterizando um maior fornecimento de potência (Villalva; Gazoli, 2012).

Figura 6 – Curvas I-V da placa CS6U em relação à irradiação e temperatura



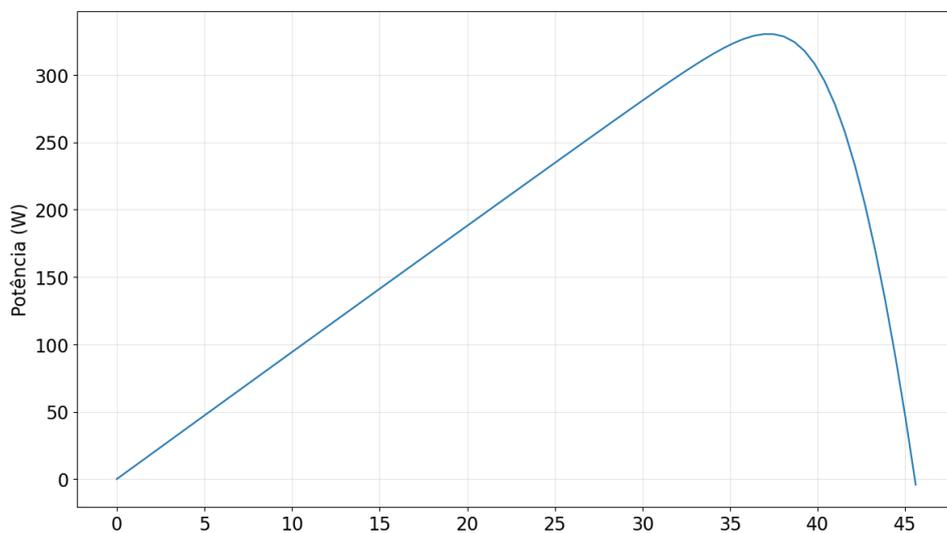
Fonte: Especificação das placas MAXPOWER CS6U-315 | 320 | 325 | 330P disponibilizadas pelo fabricante

Na Figura 6 (b) pode-se verificar mesma relação I-V, porém variando a temperatura e mantendo a irradiância em STC de 1.000 W/m². Mas agora é caracterizada uma perda de eficiência com o aumento da temperatura na placa, com uma corrente próxima do valor nominal, mas com redução do valor da tensão.

Em ambos os casos é verificado um valor de corrente constante para tensões até 75% da tensão nominal, caracterizando que a placa fotovoltaica se comporta como uma fonte de corrente (Villalva; Gazoli; Filho, 2009).

O gráfico P-V pode ser traçado calculando-se um vetor com os valores da potência em cada ponto como multiplicação entre corrente e tensão *versus* o vetor com valores de tensão. Para esta placa considera-se a tensão nominal em STC informada no catálogo de 45,6V. O gráfico P-V da placa CS6U consta na Figura 7.

Figura 7 – Curvas P-V da placa CS6U



Fonte: Autoria Própria

A corrente pode ser calculada utilizando iteração pela equação (2) (Villalva; Gazoli; Filho, 2009).

$$I = I_{pv} - I_0 \left[e^{\left(\frac{V + R_s I}{N_s V_t a} \right)} - 1 \right] - \frac{V + R_s I}{R_p} \quad (2)$$

Onde:

- I Corrente fornecida pelo painel (A)
- I_{pv} Fotocorrente gerada (A)
- I_0 Corrente de saturação reversa do diodo (A)
- V Tensão nos terminais do painel (V)
- N_s Números de células em série no painel
- V_t Tensão nos terminais da célula (V)
- a Fator de idealidade do diodo
- R_s Resistência série (Ω)
- R_p Resistência paralelo (Ω)

Os valores de I_{pv} , I_0 , a, R_s e R_p são calculados por meio de modelagem e serão discutidos no item 4.2 deste capítulo. O valor de N_s é 72, dado de especificação do equipamento fornecido pelo fabricante.

O valor da tensão nos terminais da célula de um painel pode ser calculado pela equação (3):

$$V_t = \frac{kT}{q} \quad (3)$$

Onde:

- k Constante de Boltzman ($1,38 \cdot 10^{-23}$ J/K)
- T Temperatura da célula (K)
- q Carga de um elétron ($1,6 \cdot 10^{-19}$ C)

4.2 Modelagem de painéis fotovoltaicos

Para otimizar a eficiência da utilização de módulos fotovoltaicos, é essencial contar com métodos de modelagem robustos. Estes têm como finalidade antecipar o desempenho de um sistema fotovoltaico em condições diversas daquelas inicialmente caracterizadas e descritas nas fichas técnicas do fabricante (Mellit; Kalogirou, 2022).

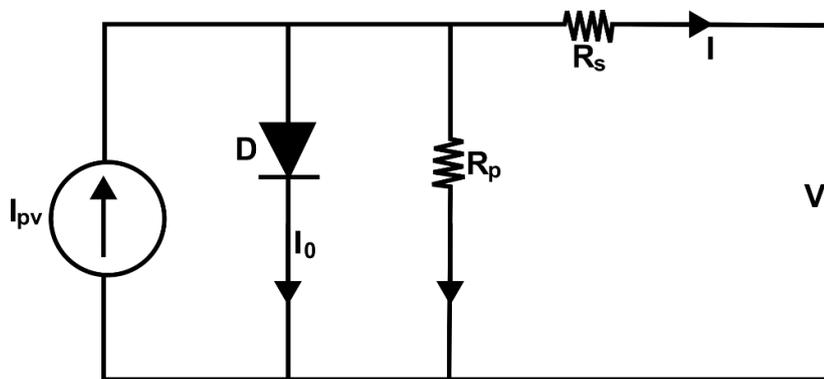
Modelos precisos podem ajudar em estudo do comportamento de células solares, monitoramento do desempenho do sistema, acompanhar a eficiência e produção de energia do sistema ao longo do tempo, análise de perdas em sistemas

fotovoltaicos, previsão da potência de saída, desenvolvimento e teste de algoritmos de MPPT (*Maximum Power Point Tracking*) e diagnóstico de falhas em sistemas fotovoltaicos (Mellit; Kalogirou, 2022).

Dados com qualidade e quantidade suficientes são necessários para realizar o treinamento de uma rede neural a ser aplicada para identificação ou classificação de faltas (Géron, 2022).

O modelo que será utilizado neste trabalho é o modelo de cinco parâmetros por ser um dos modelos mais utilizados academicamente e comercialmente. A representação esquemática deste modelo por ser vista na Figura 8.

Figura 8 - Circuito equivalente de modelo PV com um diodo



Fonte: (Mohapatra; Nayak; Mohanty, 2013)

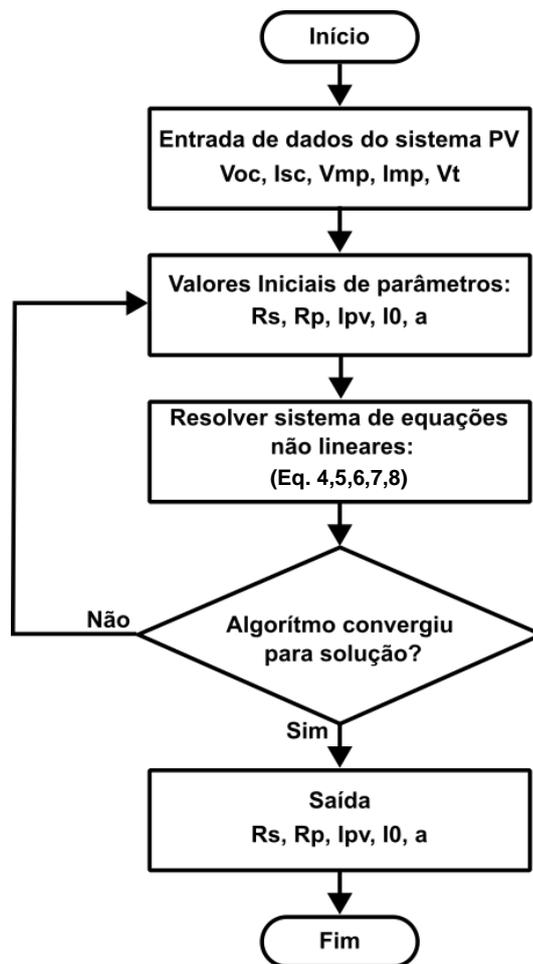
No modelo de um diodo são utilizados cinco parâmetros a serem definidos, sendo I_{pv} a fotocorrente gerada, I_0 corrente de saturação reversa do diodo, a fator de idealidade do diodo, R_s resistência série e R_p resistência paralelo. A corrente I fornecida pelo painel fotovoltaico representado pode ser calculada subtraindo-se da fotocorrente gerada o valor da corrente que passa no diodo e o valor da corrente que passa pela resistência paralelo, conforme equação (2).

Os parâmetros I_{pv} , I_0 , a , R_s e R_p não são dados pelo fabricante dos módulos, mas podem ser calculados pela técnica iterativa como a de Newton-Raphson modificada descrita em Mohapatra, Nayak e Mohanty (2013) ou pelo método iterativo de Villalva, Gazoli e Filho (2009). A seguir será explanado o cálculo dos parâmetros de modelagem da célula fotovoltaica, conforme esboçado no fluxograma da Figura 9.

Para possibilitar o cálculo das cinco variáveis é montado um sistema de equações não lineares formado por cinco funções deriváveis resolvido por técnica de

otimização. Em substituição ao programa Matlab utilizado em Mohapatra, Nayak e Mohanty (2013), foi utilizada função de otimização da biblioteca SciPy (Pauli Virtanen *et al.*, 2020) para Python, linguagem de programação bastante popular e utilizada em projetos nas áreas de *big data*, aprendizado de máquina e computação científica. Na Figura 9 consta o fluxograma demonstrando o processo de cálculo das cinco variáveis do modelo.

Figura 9 - Fluxograma de Algoritmo de cálculo de parâmetros de PV



Fonte: Adaptado de (Mohapatra; Nayak; Mohanty, 2013)

Considerando as condições do modelo em curto-circuito, circuito aberto e no ponto de potência máxima, obtém-se as funções $f_1(x)$, equação (4), $f_2(x)$, equação (5), e $f_3(x)$, equação (6), por meio da aplicação da equação (2), com objetivo de serem definidas funções objetivas com valor zero.

$$f_1(x) = I_{pv} - I_0 \left(e^{\frac{I_{sc}R_s}{V_t N_s A}} - 1 \right) - \frac{I_{sc}R_s}{R_p} - I_{sc} \quad (4)$$

$$f_2(x) = I_0 \left[e^{\left(\frac{V_{oc}}{V_t N_s A} \right)} - 1 \right] - \frac{V_{oc}}{R_p} - I_{pv} \quad (5)$$

$$f_3(x) = I_{pv} - I_0 \left[e^{\left(\frac{V_{mp} + I_{mp}R_s}{V_t N_s A} \right)} - 1 \right] - \frac{V_{mp} + I_{mp}R_s}{R_p} - I_{mp} \quad (6)$$

Onde:

V_{oc} Tensão do painel em circuito aberto (V)

V_{mp} Tensão no ponto de potência máxima (V)

I_{mp} Corrente no ponto de potência máxima (A)

A função $f_4(x)$, equação (7), é obtida no ponto de potência máxima considerando valor zero para derivada da potência em relação à tensão na condição $V = V_{mp}$ e a $f_5(x)$, equação (8), é obtida considerando valor $-1/R_p$ para a derivada da corrente em relação à tensão na condição $I = I_{mp}$, com objetivo de serem definidas funções objetivas com valor zero.

$$f_4(x) = V_{mp} \left[\frac{\frac{I_0}{V_t N_s A} e^{\left(\frac{V_{mp} + I_{mp}R_s}{V_t N_s A} \right)} + \frac{1}{R_p}}{1 + \frac{R_s I_0}{V_t N_s A} e^{\left(\frac{V_{mp} + I_{mp}R_s}{V_t N_s A} \right)} + \frac{R_s}{R_p}} \right] - I_{mp} \quad (7)$$

$$f_5(x) = \frac{\frac{I_0}{V_t N_s A} e^{\left(\frac{I_{sc}R_s}{V_t N_s A} \right)} + \frac{1}{R_p}}{1 + \frac{R_s I_0}{V_t N_s A} e^{\left(\frac{I_{sc}R_s}{V_t N_s A} \right)} + \frac{R_s}{R_p}} - \frac{1}{R_p} \quad (8)$$

A função de minimização da ferramenta SciPy é utilizada aplicando técnica de otimização Nelder-Mead com objetivo de achar valor x^* , equação (9), para o ponto de mínimo da função objetivo formada pela soma dos quadrados das cinco funções dispostas nas equações (4), (5), (6), (7) e (8). O processo de minimização visa ajustar o valor de x de maneira a minimizar o resultado da função objetivo, proporcionando assim uma solução que atenda aos critérios estabelecidos. Esse método de

otimização é eficaz na busca pelo mínimo local da função, contribuindo para a resolução eficiente do problema em questão.

O método Nelder-Mead, ou *downhill simplex*, foi proposto em 1965 e é comumente aplicado em otimizações não lineares multidimensionais onde não são necessárias informações adicionais da função objetivo como derivada ou jacobiana, além de permitir definir limites mínimo e máximo para cada variável independente de x .

$$x^* = (R_s, R_p, a, I_{pv}, I_0) : \min[f_1^2(x) + f_2^2(x) + f_3^2(x) + f_4^2(x) + f_5^2(x)] \quad (9)$$

A escolha dos valores iniciais das variáveis R_s, R_p, a, I_{pv} e I_0 desempenha um papel crucial no processo de otimização, pois influencia diretamente a convergência da solução. Deve-se selecionar cuidadosamente esses valores para evitar que o algoritmo de otimização se restrinja a mínimos locais e não alcance o valor ótimo global da função. Valores iniciais inadequados podem resultar em soluções subótimas, limitando a capacidade do algoritmo de explorar eficientemente o espaço de busca.

A definição dos valores iniciais utilizados na otimização é importante para se evitar que a solução convirja em valor mínimo local, não atingindo um valor ótimo global. Para valores iniciais de R_p e I_{pv} são utilizadas as equações (10) e (11), respectivamente, enquanto para o valor de a devem ser adotados valores típicos entre 1 e 1,5 (Mohapatra; Nayak; Mohanty, 2013).

$$R_{p,\min} = \frac{V_{mp}}{I_{sc} - I_{mp}} - \frac{V_{oc} - V_{mp}}{I_{mp}} \quad (10)$$

$$I_{pv,n} = \frac{R_p + R_s}{R_p} I_{sc} \quad (11)$$

O valor de R_s pode ser iniciado com valor muito próximo de zero e o valor inicial de I_0 pode ter valor inicial estimado pela equação (12) (Raimundo *et al.*, 2023).

$$I_0 = \left(I_{sc} - \frac{V_{oc} - I_{sc}R_s}{R_p} \right) e^{\frac{-V_{oc}}{N_s V_t}} \quad (12)$$

Foram realizadas simulações com o valor de a com valores variando entre 1 e 1,5 com passo de 0,1 e o melhor resultado atingido foi adotando o valo de 1,3, com a função objetivo resultando em valor 5×10^{-12} . Os parâmetros de modelagem para o painel, o modelo MAXPOWER CS6U-330P, são obtidos aplicando-se a técnica de cálculo de modelagem descrita acima e os valores declarados no modelo implementado no programa de modelagem Hypersim estão apresentados na Tabela 2.

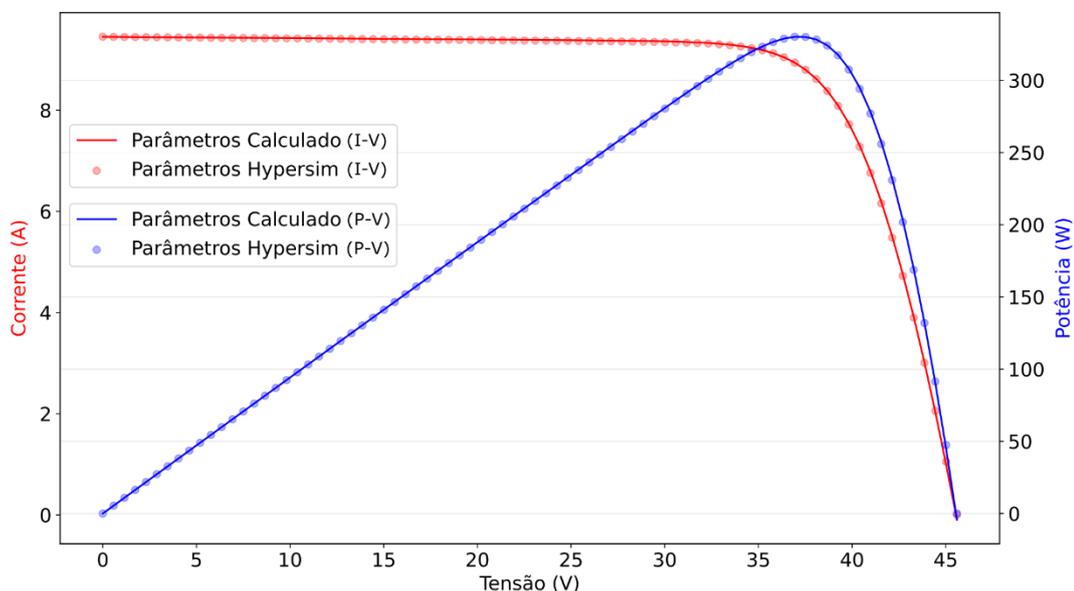
Tabela 2. Parâmetros calculados para MAXPOWER CS6U-330P

Parâmetro	Calculado	Hypersim
R_s	0,32151 Ω	0,34956 Ω
R_p	373,74580 Ω	306,55080 Ω
a	0,99497	0,94442
I_{pv}	9,45813A	9,46078A
I_0	1.66609e-10A	4,29835e-11A

Fonte: Autoria Própria

Pode-se comparar a resposta do modelo calculado com a resposta do modelo do programa de simulação adotado através das curvas I-V e P-V, considerando irradiância $G = 1.000\text{W/m}^2$ e temperatura $T = 25^\circ\text{C}$. Pode-se verificar na Figura 10 que as curvas dos modelos são coincidentes. Foram utilizadas linhas contínuas para traçar as curvas usando-se os parâmetros calculados, e foram utilizados marcadores circulares para traçar as curvas com parâmetros do Hypersim.

Figura 10 - Curvas I-V e P-V dos modelos calculados e do programa de modelagem



Fonte: Autoria Própria

4.3 Falhas em painéis fotovoltaicos

As ocorrências de falhas em sistemas fotovoltaicos podem ser categorizadas em dois grupos distintos: falhas em corrente contínua e falhas em corrente alternada, apresentando características permanentes ou temporárias. Falhas que se manifestam em corrente contínua exibem traços específicos, como uma baixa corrente de falta, tornando-se ainda mais desafiadoras de serem identificadas, quando comparadas às falhas em corrente alternada. Além disso, essas falhas podem resultar em danos mais severos às placas antes mesmo de serem detectadas (Ghaffarzadeh; Azadian, 2019).

Sistemas de supervisão contínua, baseados em algoritmos de inteligência artificial e aprendizado de máquina, podem desempenhar um papel crucial na identificação precoce dessas falhas, minimizando danos às placas fotovoltaicas e otimizando a manutenção.

Estudos indicam que falhas em níveis mais baixos de irradiação têm maior probabilidade de passarem despercebidas (Basnet; Chun; Bang, 2020). Essas falhas não detectadas podem resultar em perdas significativas de energia e degradação na qualidade do painel, podendo até levar à deterioração dos próprios painéis (Basnet; Chun; Bang, 2020).

Devido à utilização massiva de eletrônica de potência em geração fotovoltaica para conversão da geração em corrente contínua para fornecimento em corrente alternada, as proteções convencionais enfrentam desafios devido a comportamento e características atípicas durante as faltas como baixa contribuição de corrente de curto-circuito para sensibilidade das proteções convencionais, necessitando de esquemas especiais de proteção (Brasil; Empresa de Pesquisa Energética; Ministério de Minas e Energia, 2020).

Um sistema de supervisão adequado aplicado em sistemas fotovoltaicos para detecção de falhas ao processar informações sobre os parâmetros do sistema e analisar padrões elétricos nos dados fornecidos pelas ferramentas de aquisição de dados existentes nos sistemas fotovoltaicos auxilia na decisão de quais situações requerem atenção especial, evitando operações de manutenção desnecessárias e prevenindo a ocorrência prolongada de falhas críticas (Bharath; Haque; Khan, 2018).

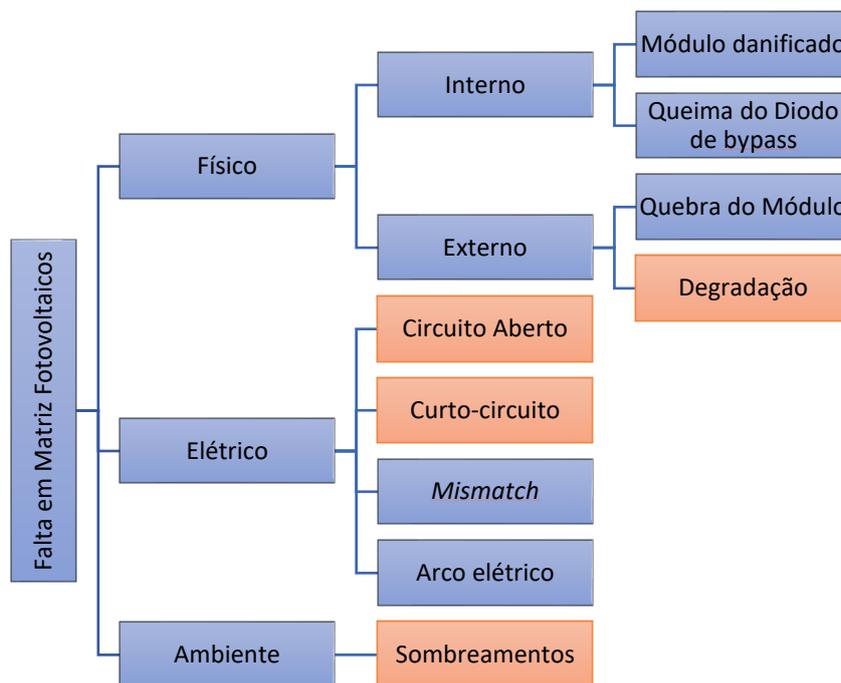
São diversas as possíveis falhas no sistema fotovoltaico que podem causar faltas em corrente contínua. Entre elas estão depósito de poeira/folhas, pontos quentes, microfissuras, degradação dos módulos, quebra de células, falhas de montagem, falha de componentes e raios (Ghaffarzadeh; Azadian, 2019).

As faltas também podem ser caracterizadas como causas permanentes ou temporárias. Em Ghaffarzadeh e Azadian (2019) são citados como exemplo de faltas de causas permanentes pontos quentes, sombras permanentes provocadas, por exemplo, por prédios, microfissuras em módulos e delaminação de células. Na mesma fonte, são citados exemplos de causas temporárias: sombra em painéis provocadas por nuvens, cobertura de painéis por neve e depósito de sujeira.

Para a realização de estudo de classificação de falhas faz-se necessário definição clara dos tipos de faltas e forma de simulação de cada tipo de falta considerada, assim como foi realizado em todos os trabalhos citados na Tabela 1.

Na Figura 11 é realizada classificação do tipo de faltas em painéis fotovoltaicos. Foram salientados os tipos de faltas a serem estudados neste trabalho: degradação, circuito aberto, curto-circuito e sombreamento. Serão consideradas as faltas por degradação em módulos fotovoltaicos ou células, faltas de circuito aberto em *strings*, curto-circuito no sistema de corrente contínua e sombreamento dos módulos. Desta forma, o estudo considera faltas de natureza física, elétrica e ambiental.

Figura 11 – Classificação de faltas em matriz fotovoltaica



Fonte: Adaptado de (Basnet; Chun; Bang, 2020)

A degradação em módulos fotovoltaicos pode ser provocada por condições ambientais, elétricas ou físicas. Este defeito muitas vezes resulta na diminuição da capacidade de geração de energia do sistema. Estratégias de manutenção preventiva otimizada suportada por sistemas de supervisão e cuidados na fabricação de células solares são fundamentais para minimizar os efeitos da degradação (Basnet; Chun; Bang, 2020).

Faltas de circuito aberto ocorrem quando há interrupção no fluxo de corrente em um ou mais *strings* de módulos fotovoltaicos. Isso pode ser causado por conexões soltas, falhas nos diodos de *bypass* ou danos físicos nos cabos. A implementação de técnicas de inspeção visual, termografia infravermelha e monitoramento remoto pode ajudar a identificar e corrigir rapidamente essas faltas (Ghaffarzadeh; Azadian, 2019).

Curto-circuitos representam um risco significativo para a integridade do sistema fotovoltaico. Podem ocorrer devido a falhas nos inversores, cabos defeituosos ou danos aos módulos. Além de medidas preventivas na instalação, como o uso de cabos de alta qualidade e inversores confiáveis, a implementação de sistemas de proteção, como disjuntores e fusíveis, é crucial para evitar danos mais sérios e garantir a segurança operacional do sistema (Ghaffarzadeh; Azadian, 2019).

Sombreamento parcial ou total dos módulos fotovoltaicos é um problema que

reduz drasticamente a produção de energia e podem causar pontos quentes nos módulos (Ghaffarzadeh; Azadian, 2019). Isso pode ser causado por obstruções naturais, como árvores, construções ou até mesmo pela própria sombra de um módulo sobre o outro.

Os quatro tipos de faltas simuladas nesta pesquisa podem ter natureza permanente ou temporária. As faltas permanentes são causadas por falhas ligadas ao equipamento onde há necessidade de troca de peças ou do próprio módulo para que o sistema volte a funcionar de forma normal (Ghaffarzadeh; Azadian, 2019).

Já as falhas temporárias podem durar por um curto período e serem solucionadas sem necessidade de intervenção, como no caso de nuvem, ou pode ser necessário manutenção para extinguir o caso da falha, como depósito de sujeitas nas placas (Ghaffarzadeh; Azadian, 2019).

Falhas temporárias que não são resolvidas podem levar a falhas permanentes como por exemplo no caso de depósito de sujeira que causam pontos quentes e quando não tratado podem causar danos permanentes à placa. Um sistema de classificação de faltas em um sistema fotovoltaico auxilia no tratamento precoce de falhas temporárias evitando que evolua para danos permanentes na placa (Ghaffarzadeh; Azadian, 2019).

A detecção antecipada de falhas é essencial para minimizar perdas de energia e garantir a operação adequada dos sistemas fotovoltaicos. Essa abordagem permite tomar decisões proativas, planejar a manutenção com antecedência e evitar períodos prolongados de baixo desempenho (De Benedetti *et al.*, 2018).

5 OTIMIZAÇÃO E APLICAÇÃO DA ARQUITETURA DO MODELO PERCEPTRON DE MULTICAMADAS NA CLASSIFICAÇÃO DE FALTAS DE FOTOVOLTAICAS

A escolha dos hiperparâmetros influencia diretamente no desempenho da rede neural. Não só os hiperparâmetros, mas outros fatores como quantidade, características e qualidade dos dados de treinamento devem ser cuidadosamente definidos no intuito de evitar sobreajuste (*overfitting*) ou subajuste (*underfitting*) do modelo (Géron, 2022).

Técnicas comumente utilizadas para definição de hiperparâmetros são *manual search* (busca manual), *grid search* (busca em grade), *random search* (busca aleatória) e *bayesian optimization* (otimização bayesiana). Uma limitação significativa da abordagem manual reside na complexidade de reproduzir resultados de maneira consistente. Essa dificuldade não apenas impacta o avanço da pesquisa científica em aprendizado de máquina, mas também compromete a aplicação prática de algoritmos de aprendizado por usuários não especializados. (Bergstra; Bengio, 2012).

A abordagem de busca manual de hiperparâmetros em redes neurais envolve a experimentação e ajuste iterativo de diversos parâmetros da rede com base na experiência do desenvolvedor ou pesquisador. Essa abordagem é realizada de forma manual, sem o auxílio de técnicas automatizadas. O processo de busca manual geralmente começa com a definição de um conjunto inicial de hiperparâmetros com base em conhecimento prévio, intuição ou experiências anteriores. A rede neural é então treinada usando esses parâmetros iniciais. Com base nos resultados, o desenvolvedor ajusta manualmente os hiperparâmetros, buscando melhorar o desempenho da rede.

Dos 10 trabalhos listados na Tabela 1, sete apenas informam a arquitetura da rede neural utilizada, sem relatar utilização de qualquer tipo de técnica de critério de escolha para definição de hiperparâmetros e três relatam utilização de um teste manual automatizado.

Em Bharath, Haque e Khan (2018) foram testados modelos de uma camada contendo entre 4 e 40 neurônios e definido utilização de 12 neurônios. Em Da Costa *et al.* (2019) foram testados modelos de uma camada entre 10 e 100 neurônios e definido utilização de 33 neurônios. Em Lazzaretti *et al.* (2020) foram testados modelos de uma camada oculta única entre 5 e 30 neurônios e definido utilização de

21 neurônios.

Na prática, a busca em grade também não se apresenta como uma solução eficaz. Apesar de varrer todas as possibilidades de hiperparâmetros, demanda um esforço computacional grande para modelos com muitas possibilidades de hiperparâmetros (Bergstra; Bengio, 2012). Esta técnica pode ser aplicada adequadamente quando se está explorando poucas combinações de parâmetros (Géron, 2022). Para obter resultados satisfatórios com esta técnica, geralmente é necessário um grande número de pontos de amostragem e é demandado um alto custo de processamento computacional (Michelucci, 2022).

O processo de busca em grade envolve a criação de uma grade, onde cada célula representa uma combinação específica de valores para os hiperparâmetros. O modelo é treinado e seu desempenho é avaliado para cada combinação de hiperparâmetros na grade. Isso é feito por meio de treinamento do modelo com os dados de treinamento, validação do desempenho com dados de validação e, finalmente, avaliação em um conjunto de teste separado. O objetivo é identificar a combinação de hiperparâmetros que resulta no melhor desempenho, geralmente medido por métricas específicas, como acurácia, precisão ou dependendo da tarefa em questão.

A busca aleatória envolve a seleção aleatória de combinações de hiperparâmetros para treinar o modelo e avaliar seu desempenho. O espaço ou conjunto dos hiperparâmetros são definidos inicialmente, são geradas combinações dentro do conjunto de hiperparâmetros definidos, seguido do treinamento/avaliação dos modelos e posteriormente é feita a seleção do melhor modelo (Bergstra; Bengio, 2012).

É observado por Michelucci (2022) que a busca aleatória é mais eficaz em obter resultados consistentemente mais próximos do máximo real que a busca em grade, mostrando exemplos práticos para embasar sua afirmação.

A otimização bayesiana é uma abordagem mais sofisticada para otimizar hiperparâmetros de redes neurais artificiais e outros modelos de aprendizado de máquina. Ela utiliza modelos probabilísticos processo gaussiano (GP do inglês *gaussian process*) para encontrar as melhores combinações de hiperparâmetros, em vez de depender de tentativas aleatórias, como na Busca Aleatória (Snoek; Larochelle; Adams, 2012).

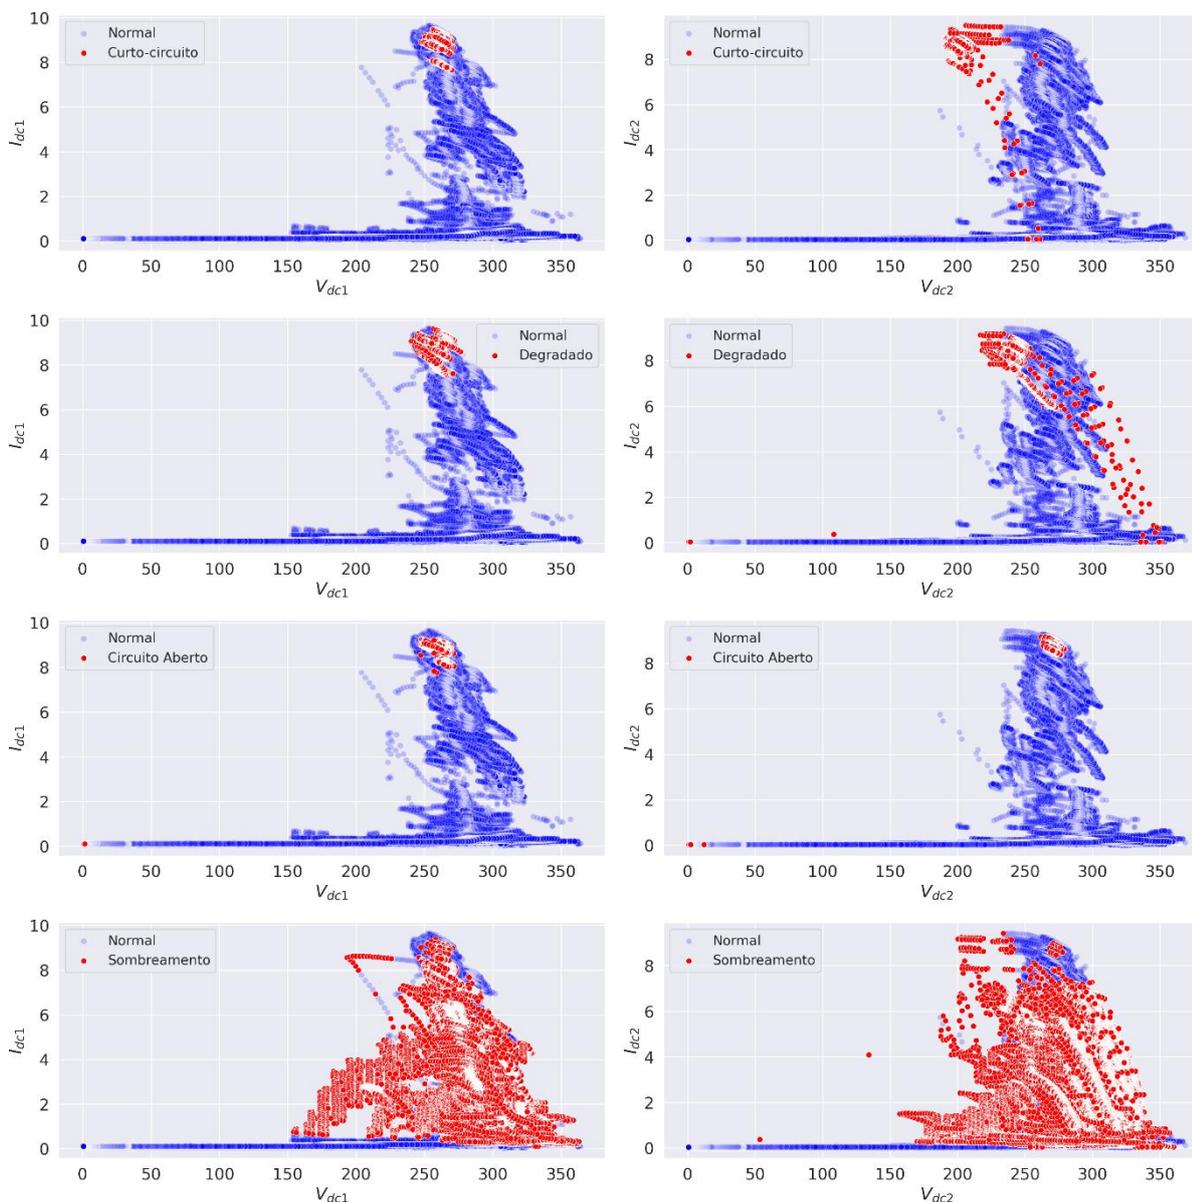
A busca aleatória pode ser preferível em situações em que a simplicidade, a disponibilidade de recursos computacionais limitados e a exploração abrangente do espaço de hiperparâmetros são mais importantes do que a busca eficiente e inteligente. No entanto, é importante notar que a escolha entre a busca aleatória e a otimização bayesiana depende do contexto específico do problema e dos recursos disponíveis, e cada abordagem tem seu lugar nas estratégias de otimização de hiperparâmetros (Snoek; Larochelle; Adams, 2012).

A escolha da busca aleatória pode demandar menos recursos computacionais, já que a busca de grade passa por todas as possibilidades de combinação e a otimização bayesiana inicia com um modelo probabilístico, e a construção desse modelo pode ser computacionalmente custosa (Snoek; Larochelle; Adams, 2012).

O sistema fotovoltaico em operação onde foi coletado a base de dados utilizada para treinamento, validação e classificação foi descrita no Capítulo 3.

A classificação de falta com utilização de métodos determinísticos convencionais utilizando valores de correntes e tensões em corrente contínua se torna uma tarefa difícil. Pode-se verificar esta dificuldade de classificação de forma visual por meio dos gráficos do tipo I-V com pontos de operação normal e de falta na Figura 12. Os pontos em vermelho marcam operação com falhas de curto-circuito, módulos degradados, circuito aberto e sombreamento e os pontos em azul são medições em operação normal. Os pontos de medição em situação de falha e em situação de operação normal se encontram aproximadamente na mesma região.

Figura 12 – Gráficos I-V com pontos de falha e operação normal



Fonte: Autoria Própria

No que diz respeito à quantidade de registros utilizados, não há uma quantidade padrão para treinamento e validação nos trabalhos usados como referência na pesquisa, citados na Tabela 1. Em *Chine et al. (2016)* foi utilizada uma base de dados com 775 registros com 620 utilizados para treinamento (80%) e 155 para teste (20%). Já *Lazzaretti et al. (2020)* realizou verificação do resultado em matriz de testes com um total de 512.284 registros.

Um percentual comum de separação dos registros da base de dados para treinamento/validação e teste é de 80% e 20% respectivamente, porém um cuidado

ao definir a quantidade de registros para treinamento é não haver uma quantidade muito grande que cause um sobreajuste do modelo, causando um bom trabalho de classificação nos dados de treinamento e validação e um mal desempenho na fase de teste, ou seja, quando o modelo é colocado em operação (Géron, 2022).

A base de dados utilizada na pesquisa tem um total de 1.373.798 registros, sendo 1.162.931 com sistema sem falta aplicada, 5.999 em situação de curto-circuito, 10.371 com degradação, 6.024 com circuito aberto e 188.473 com sombra em um ou mais módulos. Destas quantidades, foram selecionadas 20% da base para treinamento e validação (274.759 registros), sendo a seleção de forma aleatória, mas proporcional à quantidade de cada tipo de ocorrência.

Os demais registros foram utilizados no teste de previsão. Considerar 80% dos registros da base de dados para treinamento e validação seria uma quantidade muito maior que as utilizadas nos trabalhos considerados como referência.

A separação de dados nestes dois conjuntos de registros foi realizada de forma aleatória em amostras estratificadas, ou seja, mantendo a proporção de classificação de faltas com 84,65% dos registros em condição de operação normal, 0,44% em condições de curto-circuito, 0,75% em condições de degradação, 0,44% de circuito aberto e 13,72% em condições de sombreamento.

A definição da faixa dos valores e características na otimização de cada hiperparâmetro foi definida com base na Tabela 1.

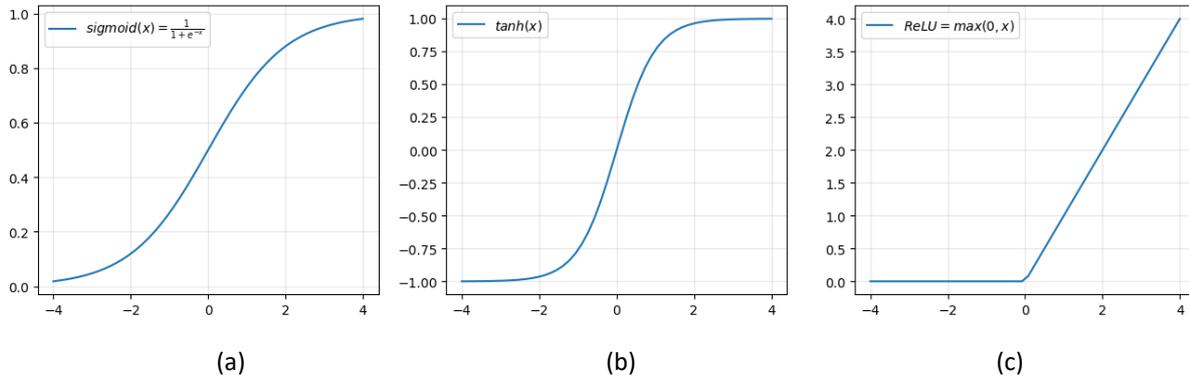
O papel da função de ativação na rede neural artificial é transformar a função resultante da rede não linear, sem a função de ativação a rede neural seria apenas uma transformação linear (Géron, 2022). As funções de ativação consideradas no processo de *tuning* de hiperparâmetros foram sigmoidal, tanh (tangente hiperbólica) e ReLU (*Rectified Linear Unit*), visualizadas nas Figura 13 (a), (b) e (c) respectivamente.

Em Rao, Spanias e Tepedelenlioglu (2019) a função de ativação utilizada foi a tanh com decisão baseada em experiência prévia dos autores. A utilização da tanh como função de ativação tem bons resultados quando aplicados em dados normalizados (Géron, 2022).

Nos modelos que foi utilizada a tangente hiperbólica, o kernel de inicialização utilizado foi o método Glorot para lidar melhor com estabilização da convergência no treinamento, já que esta função de estabilização é mais íngreme comparada ao ReLU e à sigmoidal (Géron, 2022). Para as funções ReLU e sigmoidal o kernel de inicialização da otimização foi usado inicialização He, também conhecida como

inicialização Kaiming.

Figura 13 – Gráfico de funções de ativação



Fonte: Autoria Própria

A função ReLU é computacionalmente eficiente, pois é simples de calcular e não envolve operações exponenciais como a tanh ou a sigmoideal, além de ajudar a mitigar o problema de desvanecimento de gradiente por possuir uma derivada constante para valores positivos. A simplicidade da aplicação da função ReLU pode ser verificada na equação (13) (Géron, 2022). (Michelucci, 2022) coloca que para redes neurais com saídas 0 ou maiores a função de ativação que deve ser usada é a ReLU.

$$\text{ReLU}(z) = \max(0, z) \quad (13)$$

Por mapear os valores para o intervalo (0, 1), a função sigmoideal, equação (14), é útil em problemas de classificação binária, onde a saída representa a probabilidade, apesar de poder sofrer problema de desvanecimento de gradiente, especialmente em redes neurais profundas.

$$\text{sigmoideal}(z) = \frac{1}{1+e^{-z}} \quad (14)$$

A função de ativação softmax foi definida como camada de saída para garantir uma saída com probabilidade de cada classificação, assim como nos trabalhos de Basnet, Chun e Bang (2020), Lazzaretti *et al.* (2020) e Rao, Spanias e Tepedelenlioglu

(2019). A função softmax transforma um vetor de k dimensões em outro vetor de valores reais de k dimensões, cada um dos valores entre 0 e 1, que a soma é 1 (Michelucci, 2022). É uma função muito útil para redes neurais artificiais de classificação, já que o vetor de saída corresponde à probabilidade calculada de cada valor de classificação ser verdadeiro. O valor da função softmax da classe i considerando um vetor de saída de classificação com k elementos pode ser calculado pela equação (15) (Goodfellow; Bengio; Courville, 2016).

$$\text{softmax}(x)_i = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (15)$$

Como interessa apenas a saída da rede neural, vinda da função softmax, equação (15), com maior probabilidade de ser a classificação correta, pode-se utilizar a função argmax como complemento à saída. Esta função retorna o índice da saída de maior probabilidade, transformando novamente em uma classificação de índice entre 0 e 4 (Géron, 2022). Para aplicação da função argmax em um vetor formado de números, pode-se representar a função pela equação (16).

$$\underset{x \in X}{\operatorname{argmax}}(X) = i \mid i \in \mathbb{N}; x_i \geq x_j; \forall j \in \mathbb{N} \quad (16)$$

Como exemplo do funcionamento da função argmax, define-se a lista de classificações como possibilidade de saída a situação normal (índice 0), curto-circuito (índice 1), módulos degradados (índice 2), circuito aberto (índice 3) e sombreamento (índice 4). Considerando uma classificação da rede neural artificial que tenha saída da função softmax o vetor [0,03 0,03 0,92 0,02 0,02], ao se aplicar o vetor de saída na função argmax o resultado seria o valor 2, que corresponde ao índice de maior probabilidade.

A camada de entrada conta com quatro neurônios, equivalentes à quantidade de entradas de números reais no modelo que são valores de duas correntes em corrente contínua e duas tensões em corrente contínua.

Após a camada de entrada é aplicada uma camada de normalização. Os trabalhos de Chine *et al.* (2016), Sabri, Tlemçani e Chouder (2019) e Basnet, Chun e Bang (2020) citam que aplicam camada de normalização nos dados de entrada em redes neurais perceptron de multicamadas.

A utilização desta camada de normalização tem como objetivo o de garantir estabilidade e eficiência para o treinamento da rede neural (Sabri; Tlemçani; Chouder, 2019). Ao padronizar as escalas, a técnica mitiga disparidades numéricas entre os valores de corrente e tensão, prevenindo que algumas dominem o aprendizado. Isso acelera a convergência do modelo, resultando em treinamentos mais rápidos e estáveis. Além disso, a normalização facilita a otimização, pois reduz o risco de oscilações durante o processo de atualização dos pesos.

A camada de normalização em lote foi aplicada de forma diferente para o modelo no momento do treinamento e da inferência. Durante o treinamento a camada normaliza sua saída usando a média e o desvio padrão do lote de entradas, ou seja, dados do registro de treinamento. Para cada canal sendo normalizado, a camada retorna valor da equação (17).

$$\hat{x}^{(i)} = \frac{\gamma(x^{(i)} - \mu)}{\sqrt{\{\sigma^2 + \epsilon\}}} \quad (17)$$

Onde:

- $\hat{x}^{(i)}$ Vetor de entradas normalizadas para instância i
- μ Média do vetor de entrada do lote
- σ^2 Variância do vetor de entrada do lote
- γ Vetor de parâmetros de escala
- ϵ Número pequeno evitando divisão por zero (10^{-3})

Para o momento de classificação é utilizada a mesma equação (17), com alteração do parâmetro μ sendo calculado como média móvel, o fator σ^2 como variância móvel.

Para a quantidade de camadas ocultas foram considerados modelos entre uma e três camadas, por serem os números de camadas utilizadas em artigos entre 2013 e 2023 que colocam mais informações sobre as redes neurais perceptron de multicamadas utilizadas para classificação de faltas em sistemas fotovoltaicos (Bezerra *et al.*, 2023).

Foram adotadas regras específicas para quantidade de neurônios utilizados em cada camada. No caso de definição pelo algoritmo de otimização de hiperparâmetros de um modelo de apenas uma camada, a quantidade de neurônios pode variar entre

10 e 40 neurônios. No caso de o modelo treinado contar com duas ou três camadas, os modelos testados poderiam ter mínimo de 5 e máximo de 30 neurônios em camada. Estas definições foram realizadas com intuito de otimizar o recurso computacional utilizado; caso contrário, modelos com uma camada e apenas cinco neurônios poderiam ser selecionados para teste, o que seria perda de capacidade computacional testar uma rede bem menor que a menor rede definida nos artigos de referência listados na Tabela 1.

A camada de saída conta com 5 neurônios, quantidade igual às classificações que serão previstas pelo modelo que são Operação Normal, Curto-Circuito, Sistema Degradado, Circuito Aberto e Módulo(s) com Sombra.

A fase de treinamento em redes neurais é importante para aprimorar o desempenho do modelo e garantir sua capacidade de generalização. Durante esse processo, os pesos das conexões entre as camadas da rede são ajustados para aprender representações significativas dos dados de entrada. O treinamento é realizado por meio de técnicas de treinamento, como as que serão abordadas em seguida.

No processo de convergência do modelo são ajustados iterativamente para minimizar a função de perda. A convergência eficaz garante que o modelo atinja um estado onde suas previsões se aproximam ao máximo dos rótulos verdadeiros, garantindo assim um desempenho ótimo em dados futuros não vistos.

Além disso, é durante o treinamento que os hiperparâmetros do modelo são ajustados para otimizar sua eficácia e técnicas de regularização são aplicadas para evitar o sobreajuste.

As técnicas de otimização consideradas para treinamento das redes neurais foram Gradiente Descendente Estocástico (SGD do inglês *Stochastic Gradient Descent*), RMSProp, ADAM (*Adaptive Moment Estimation*) e NADAM (*Nesterov-accelerated Adaptive Moment Estimation*).

O Gradiente Descendente Estocástico consegue trabalhar bem com grandes volumes de dados, mas é sensível à inicialização dos pesos e à taxa de aprendizagem, o que pode tornar a convergência instável ao chegar próximo do valor ótimo (Géron, 2022). O SGD é frequentemente utilizado em algoritmos de otimização para redes neurais profundas e também é considerado uma técnica de regularização utilizada por meio de otimização (Kukačka; Golkov; Cremers, 2017).

O RMSProp acumulando apenas os gradientes das iterações mais recentes,

em oposição a todos os gradientes desde o início do treinamento, mitigando os desafios de ajuste do Gradiente Descendente (Géron, 2022). Sua capacidade de se adaptar a diferentes escalas de gradientes é uma vantagem significativa, proporcionando estabilidade em muitas situações. No entanto, pode ser sensível à escolha da taxa de aprendizado e, em alguns casos, apresentar convergência prematura. A falta de momento pode levar a oscilações em direção ao mínimo global, impactando negativamente o desempenho em determinados cenários. O RMSprop foi um algoritmo de otimização utilizado por muitos pesquisadores até o surgimento do ADAM (Géron, 2022).

ADAM é um algoritmo simples e computacionalmente eficiente para otimização baseada em gradientes de funções objetivas estocásticas e adequado para problemas de aprendizado de máquina com conjuntos de dados grandes de parâmetros de alta dimensão (Kingma; Ba, 2015). O ADAM adapta a taxa de aprendizado para cada parâmetro, proporcionando flexibilidade e eficiência. Sua combinação de médias móveis dos gradientes e seus quadrados reduz a sensibilidade à escolha de hiperparâmetros, tornando-o robusto em uma variedade de cenários. Pode ocorrer *overfitting* em conjuntos de dados menores devido à adaptação rápida da taxa de aprendizado, mas que não é o caso deste trabalho.

O NADAM combina as ideias do *Nesterov Accelerated Gradient* (NAG) com o ADAM, o que geralmente resulta em uma convergência um pouco mais rápida do que o ADAM. O pesquisador Timothy Dozat introduziu esta técnica comparando vários otimizadores em várias tarefas e observou que o NADAM geralmente supera o ADAM, mas ocasionalmente é superado pelo RMSProp (Géron, 2022).

Ao incorporar a correção de momento de Nesterov, o NADAM melhora a convergência. Sua capacidade de tratar eficientemente diferentes tipos de gradientes o torna poderoso. Entretanto, o NADAM pode ser sensível a diferentes configurações de hiperparâmetros, e sua performance pode variar dependendo da arquitetura da rede neural. Além disso, em alguns casos, o NADAM pode ser computacionalmente mais pesado do que métodos mais simples.

Tabela 3. Configuração de hiperparâmetros para *tuning*.

Hiperparâmetros	Intervalo de Valor
Quantidade de camadas ocultas possíveis	1, 2 ou 3
Neurônios na primeira camada oculta	Entre 10 e 40 (MLP com apenas uma camada) Entre 5 e 30 (MLP com 1 ou 2 camadas)
Neurônios na segunda camada oculta	Entre 5 e 30
Função de ativação das camadas ocultas	Tanh, ReLU ou Sigmoide
Função de ativação da camada de saída	Softmax
Método de treinamento	SGD, RMSProp, ADAM ou NADAM
Métrica para otimização	Acurácia

Fonte: Autoria Própria.

Os parâmetros utilizados na otimização bayesiana foram descritos anteriormente e estão resumidos na Tabela 3. Os hiperparâmetros encontrados resultantes estão registrados na Tabela 4. Este modelo definido pela otimização bayesiana será nomeado de Modelo 1 para que a discussão seja facilitada.

A validação cruzada foi aplicada para definição da maior acurácia dentre os modelos definidos no processo de otimização bayesiana. Para aplicação desta técnica, a amostra de treinamento é dividida em dois subconjuntos disjuntos, um subconjunto de estimação, usado para selecionar o modelo e um subconjunto de validação, usado para testar ou validar o modelo. Dessa forma, pode-se usar a amostra de treinamento para avaliar o desempenho de vários modelos candidatos e, assim, escolher o modelo com maior valor do parâmetro de avaliação do modelo (Haykin, 2009).

No entanto, há uma possibilidade de que o modelo com os valores de parâmetros de melhor desempenho selecionados possa acabar se ajustando demais ao subconjunto de validação. Para proteger contra essa possibilidade, o desempenho de generalização do modelo selecionado é medido no conjunto de teste, que é diferente do subconjunto de validação (Haykin, 2009).

Utilizando a validação cruzada com 10% da quantidade de registros da base de dados para validação dos modelos testados e 90% para treinamento, a acurácia na fase de treinamento do melhor modelo treinado e selecionado foi de 98,49%. Esse valor caracteriza que o Modelo 1 não está subajustado, que ele tem complexidade

suficiente e que as variáveis de entrada e hiperparâmetros são adequados, já que num caso de subajuste o modelo não teria uma boa acurácia de classificação quando aplicado aos dados de treinamento,

Tabela 4. Hiperparâmetros do Modelo 1 - Otimização Bayesiana.

Hiperparâmetros	Valor
Quantidade de camadas ocultas	2
Neurônios na primeira camada oculta	17
Neurônios na segunda camada oculta	21
Função de ativação das camadas ocultas	ReLU
Função de ativação da camada de saída	softmax
Método de treinamento	ADAM

Fonte: Autoria Própria.

O Modelo 1 foi definido com duas camadas ocultas com número de neurônios distintos, o que difere dos casos de redes de duas ou três camadas estudadas nos artigos citados na Tabela 1, que sempre usaram o mesmo número de neurônios para cada camada oculta.

No processo de otimização dos hiperparâmetros foram definidas utilização de duas camadas, suficiente para atingir alta acurácia, porém aplicando mais que uma camada oculta. Em Da Costa *et al.* (2019) foi utilizada técnica de procurar a melhor rede perceptron multicamadas testando arquiteturas com apenas uma camada oculta, variando entre 10 e 100 neurônios e o melhor valor encontrado foi uma camada oculta com 33 neurônios, porém no trabalho não é informado demais características como função de ativação e método de treinamento utilizado.

A definição da função ReLU mostrou-se suficiente para atingir um bom valor de acurácia, também proporciona ganhos para o desempenho da previsão do modelo, já que é uma função de ativação mais simples. Basnet, Chun e Bang (2020) também aplicaram a função de ativação ReLU por reconhecerem diversas vantagens na aplicação em dados não lineares e em base de dados com múltiplas dimensões.

Após treinamento e validação do modelo selecionado, foi realizada a classificação do sistema para os demais 80% dos registros da base de dados que foi separada para este fim, atingindo uma acurácia de 98,42%. Um valor alto e que caracteriza que não está havendo sobreajuste do modelo, já que, apesar de conseguir uma boa acurácia de 98,49% nos dados de treinamento, o modelo também está

conseguindo uma boa generalização na classificação para os dados de teste.

Os valores de precisão, revocação e pontuação F_1 dos resultados da classificação de teste do Modelo 1 podem ser vistos na Tabela 5 e é mostrada a matriz de confusão na Figura 14. A precisão indica a proporção de instâncias corretamente classificadas, enquanto a revocação mensura a habilidade do modelo em identificar instâncias positivas. A pontuação F_1 representa uma média harmônica entre precisão e revocação, oferece uma métrica equilibrada. Por vezes a precisão e revocação têm uma relação de compromisso de acordo com a capacidade de generalização nas previsões de modelos, sendo a pontuação F_1 crucial para uma avaliação abrangente. No caso da pesquisa a revocação se mostra mais importante por acurácia na indicação instâncias positivas (falhas).

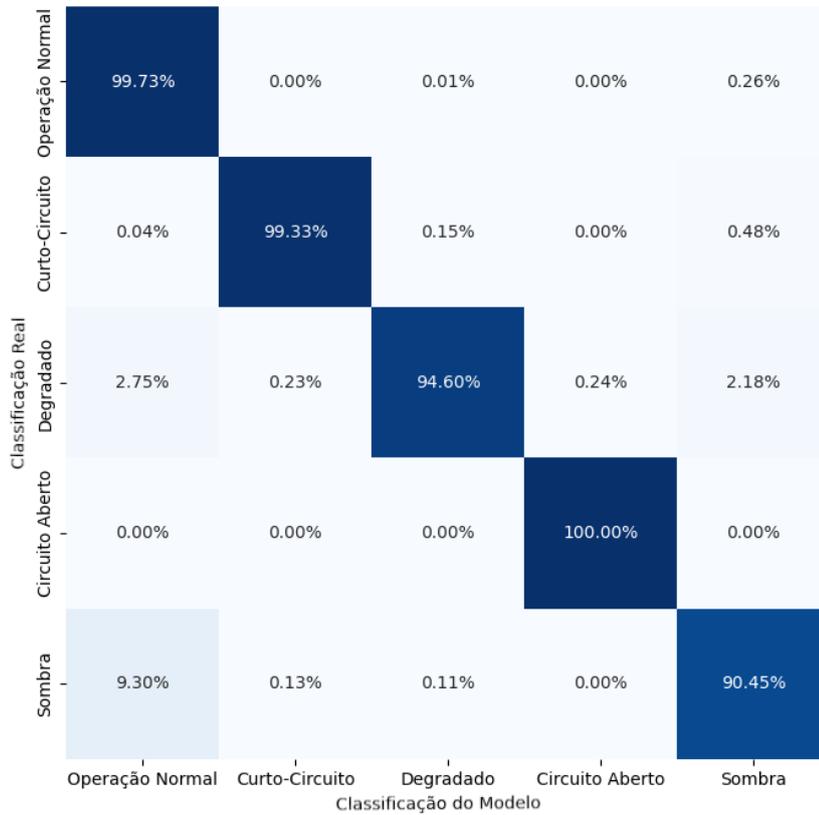
Tabela 5. Precisão e Revocação dos resultados do Modelo 1

Classe	Precisão [%]	Revocação [%]	Pontuação F_1 [%]
Operação Normal	98,49	99,73	99,11
Curto-Circuito	95,53	99,33	97,40
Sistema Degradado	97,09	94,60	95,83
Circuito Aberto	99,59	100,00	99,79
Módulo(s) com Sombra	98,10	90,45	94,12

Fonte: Autoria Própria.

De forma geral o Modelo 1 desempenhou muito bem, apesar de apresentar um desempenho menor ao classificar medidas como sendo módulo(s) com sombra, estando correto em 90,45% das classificações. Por outro lado, houve um acerto de 100% ou muito próximo deste valor para os casos de operação normal, curto-circuito e circuito aberto. Em Lazzaretti *et al.* (2020), que utilizou a mesma base de dados para teste de classificação em uma rede perceptron de multicamadas, o modelo também teve menor desempenho ao classificar sombreamento com acurácia de 89,26%, enquanto foi medido 99,35% para curto-circuito, 93,18% para degradação e 100% para circuito aberto.

Figura 14 – Matriz Confusão do Modelo 1



Fonte: Autoria Própria

Após a definição de parâmetros com a otimização bayesiana, foi realizada a definição de parâmetros utilizando a busca randômica com as mesmas possibilidades de hiperparâmetros descritos e aplicados na otimização bayesiana, conforme Tabela 3. Da mesma forma, aplicando a validação cruzada com os mesmos parâmetros, a acurácia na fase de treinamento foi de 98,30%, muito próxima do resultado encontrado com a otimização bayesiana. Este segundo modelo encontrado é nomeado de Modelo 2 e tem o resumo do resultado exposto na Tabela 6.

Tabela 6. Hiperparâmetros do Modelo 2 – Busca Randômica.

Hiperparâmetros	Valor
Quantidade de camadas ocultas	3
Neurônios na primeira camada oculta	28
Neurônios na segunda camada oculta	16
Neurônios na terceira camada oculta	15
Função de ativação das camadas ocultas	tanh
Função de ativação da camada de saída	softmax
Método de treinamento	RMSprop

Fonte: Autoria Própria.

Os valores de precisão, revocação e pontuação F_1 dos resultados da classificação de teste do Modelo 2 podem ser vistos na Tabela 7. Precisão e Revocação dos resultados do Modelo 2, e é mostrada a matriz de confusão na Figura 15. Apesar de muito próximos, todos os valores de revocação são menores ou iguais quando comparados ao Modelo 1.

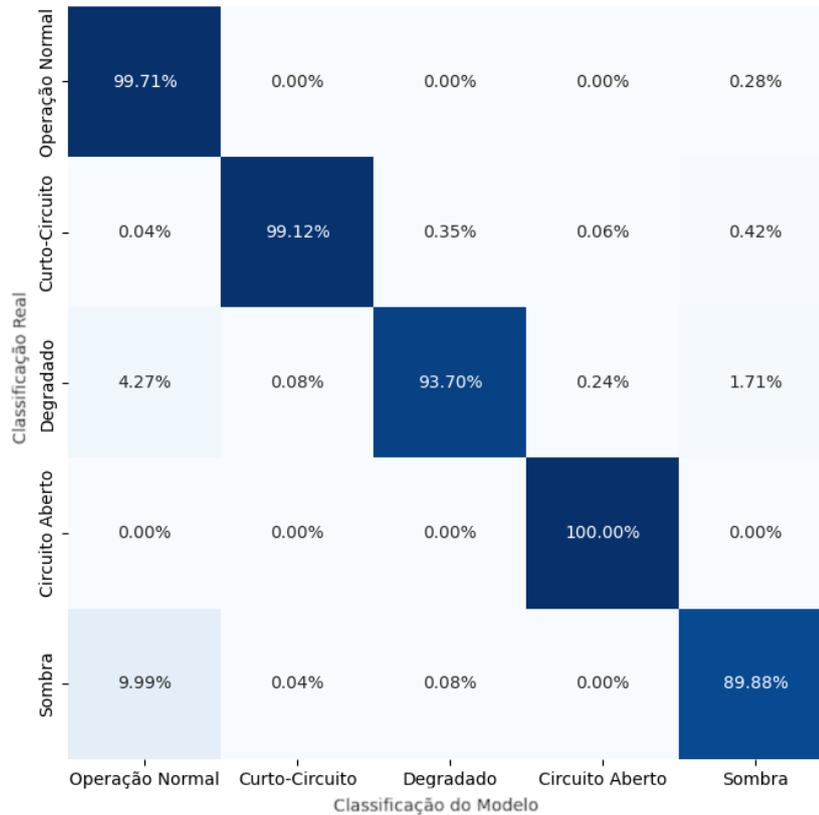
Tabela 7. Precisão e Revocação dos resultados do Modelo 2

Classe	Precisão [%]	Revocação [%]	Pontuação F_1 [%]
Operação Normal	98,37	99,71	99,03
Curto-Circuito	98,45	99,12	98,79
Sistema Degradado	97,91	93,70	95,76
Circuito Aberto	99,46	100,00	99,73
Módulo(s) com Sombra	97,97	89,88	93,75

Fonte: Autoria Própria.

Apesar da acurácia dos modelos definidos pelas diferentes técnicas de definição dos hiperparâmetros ser semelhante, pode-se constatar arquitetura de redes bem distintas. Iniciando pela quantidade de camadas e neurônios por camada.

Figura 15 – Matriz Confusão do Modelo 2



Fonte: Autoria Própria

O Modelo 1 de duas camadas conta com um total de 589 parâmetros, que é a soma dos 16 parâmetros calculados na camada de normalização (quantidade de entradas, 4, multiplicada pela quantidade de neurônios da camada de normalização, 4), 85 parâmetros da primeira camada oculta (quantidade de neurônios da camada de normalização, 4, multiplicada por quantidade de neurônios da primeira camada oculta, 17, e somada a quantidade de parâmetros do vetor de vieses, 17), 378 parâmetros da segunda camada oculta (quantidade neurônios da camada da primeira camada oculta, 17, multiplicada por quantidade de neurônios da segunda camada oculta, 21, e somada a quantidade de parâmetros do vetor de vieses, 21) e 110 parâmetros da camada de saída (quantidade de neurônios da camada da segunda camada oculta, 21, multiplicada por quantidade de neurônios da camada de saída, 5, e somada a quantidade de parâmetros do vetor de vieses, 5).

Com intuito de facilitar o cálculo de parâmetros de uma rede perceptron de multicamadas utilizando camada de normalização antes da primeira camada oculta, pode-se representar o número de parâmetros na equação (18).

$$P = k * n_1^2 + \sum_{i=2}^C n_i * (n_{\{i-1\}} + 1) \quad (18)$$

Onde:

- P Número de parâmetros da rede MLP
- k Contante referente à camada de normalização (1 se existir camada de entrada de regularização, 0 se não houver camada de regularização)
- n_i Número de neurônios na camada i
- C Número de camadas incluindo camada de entrada, camadas ocultas e camada de saída

Utilizando a equação (18), calcula-se que o Modelo 2 conta com 955 parâmetros sendo uma rede maior e mais complexa.

Foram aplicadas duas técnicas distintas para definição de hiperparâmetros e os resultados de acurácia na classificação da base de dados de teste foram bem semelhantes, o que pode ser um indicativo que os hiperparâmetros das redes neurais perceptron de multicamadas para classificação de faltas em sistemas fotovoltaicos devem ser otimizados de forma conjunta, ou seja, otimizando a rede considerando diferentes aspectos da arquitetura, no caso do teste da pesquisa a quantidade de camadas, número de neurônios por camada, função de ativação e técnica de treinamento.

Para verificar essa possibilidade, foi criado modelo nomeado Modelo 1A com os mesmos hiperparâmetros encontrados na otimização bayesiana, com exceção da função de ativação que foi utilizada a tanh no lugar da função de ativação ReLU. Outro modelo identificado como Modelo 2A foi parametrizado com os mesmos hiperparâmetros encontrados na busca randômica, com exceção da função de ativação que foi utilizada a ReLU no lugar da função de ativação tanh.

Ao serem treinados utilizando a mesma metodologia, com o mesmo conjunto de dados de treinamento e verificada acurácia com o mesmo conjunto de dados de teste o Modelo 1A teve uma acurácia de classificação de 97,41%, 1,8% menor que os 98,49% do Modelo 1. No caso do modelo definido com Modelo 2A a acurácia de 97,36%, 0,94% menor que os 98,30% do Modelo 2.

A diferença de acurácia entre os modelos com as funções de ativação alteradas foi maior que a diferença de acurácia entre os modelos otimizados, 0,19% entre os 98,49% do Modelo 1 e 98,30% do Modelo 2.

Este experimento reforça o indicativo de que os hiperparâmetros devem ser tratados como valores interligados, que devem ser otimizados em conjunto e não como configurações independentes que devem ser definidas de forma isolada.

6 CONCLUSÕES

A utilização das técnicas de *tunnig* busca randômica e otimização bayesiana para definição de hiperparâmetros de redes neurais artificiais garantem um melhor resultado na classificação do ponto de vista da acurácia, comparado à definição empírica de aspectos do modelo estudando cada característica da rede de forma isolada.

Os resultados atingidos utilizando otimização bayesiana ou busca randômica são similares, porém contam com melhor chance de acerto na definição que a busca manual, dependendo menos da experiência do pesquisador para definir redes com boa acurácia. Também necessitam de menor esforço computacional que na utilização da busca em grade.

A modelagem computacional de sistemas fotovoltaicos pode ajudar no processo de testes e treinamentos de redes neurais artificiais, reduzindo riscos provenientes de testes em sistemas em operação e provendo quantidade de registros tanto quando avaliado como necessário para o treinamento. Apesar das vantagens, é necessário cuidado para que o modelo represente o sistema fotovoltaico com respostas similares à resposta do sistema real.

Um sistema de classificação de faltas aplicado em sistemas fotovoltaicos se mostra ainda mais vantajoso em plantas instaladas em locais de difícil acesso, em locais que necessitam de grande deslocamento de profissionais para manutenção ou em sistema com grande quantidade de módulos. Um sistema de monitoramento que fornece informações sobre o estado dos módulos contribui para a minimização dos custos de manutenção, identificando falhas que requerem intervenção.

A utilização de redes neurais perceptron de multicamadas de complexidade baixa atingem uma boa acurácia na classificação de faltas dos tipos curto-circuito, sistema degradado, circuito aberto e módulo(s) com sombra. Para tanto, deve-se analisar a arquitetura mais adequada para criação de um modelo de classificação aplicado através de definição de hiperparâmetros.

6.1 Sugestões para Trabalhos Futuros

Como sugestão para trabalhos futuros na mesma linha de pesquisa pode-se listar:

- Ampliação de metodologia de classificação para detectar local exato da

falta na planta fotovoltaica além do tipo de falta;

- Considerar mais variáveis de entrada no modelo de classificação;
- Treinamento da rede neural artificial utilizando dados provenientes de modelagem computacional de sistema fotovoltaico, possibilitando treinamento da rede neural ainda antes de sua entrada em operação;
- Considerar mais premissas para definição dos hiperparâmetros além do valor da acurácia, como menor tempo de treinamento e menor tempo de classificação pela rede neural artificial.

REFERÊNCIAS

- ABADI, MARTIN *et al.* Tensorflow: A system for large-scale machine learning. **12th USENIX Symposium on Operating Systems Design and Implementation**, [s. l.], p. 265–283, 2016.
- BASNET, Barun; CHUN, Hyunjun; BANG, Junho. An Intelligent Fault Detection Model for Fault Detection in Photovoltaic Systems. **Journal of Sensors**, [s. l.], v. 2020, p. 1–11, 2020.
- BENGHANEM, Mohammed S.; ALAMRI, Saleh N. Modeling of photovoltaic module and experimental determination of serial resistance. **Journal of Taibah University for Science**, [s. l.], v. 2, n. 1, p. 94–105, 2009.
- BERGSTRA, James; BENGIO, Yoshua. Random Search for Hyper-Parameter Optimization. **Journal of Machine Learning Research**, [s. l.], p. 281–305, 2012.
- BEZERRA, Hugo Everaldo Salvador Bezerra *et al.* Comparison of multilayer perceptron neural network architecture in photovoltaic plants fault classification. **Concilium**, [s. l.], v. 23, n. 20, p. 523–536, 2023.
- BHARATH, Kurukuru Varaha Satya; HAQUE, Ahteshamul; KHAN, Mohammed Ali. Condition Monitoring of Photovoltaic Systems Using Machine Learning Techniques. *In*: 2018 2ND IEEE INTERNATIONAL CONFERENCE ON POWER ELECTRONICS, INTELLIGENT CONTROL AND ENERGY SYSTEMS (ICPEICES), 2018, Delhi, India. **2018 2nd IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**. Delhi, India: IEEE, 2018. p. 870–875.
- BRASIL. **Leilões**. [S. l.], 2024. Disponível em: <https://www.epe.gov.br/pt/leiloes-de-energia/leiloes>. Acesso em: 15 fev. 2024.
- BRASIL; AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa ANEEL Nº 1.059**. 7 fev. 2023.
- BRASIL; EMPRESA DE PESQUISA ENERGÉTICA; MINISTÉRIO DE MINAS E ENERGIA. **Estudo de integração de fontes renováveis variáveis na matriz elétrica do Brasil**. [S. l.: s. n.], 2020.
- BRASIL; MINISTÉRIO DE MINAS E ENERGIA; EMPRESA DE PESQUISA ENERGÉTICA. **Plano Decenal de Expansão de Energia 2031/ Ministério de Minas e Energia**. Brasília: Empresa de Pesquisa Energética, 2022.
- CHINE, W. *et al.* A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. **Renewable Energy**, [s. l.], v. 90, p. 501–512, 2016.
- CHOUAY, Yassine; OUASSAID, Mohammed. An intelligent method for fault diagnosis in photovoltaic systems. *In*: 2017 INTERNATIONAL CONFERENCE ON ELECTRICAL AND INFORMATION TECHNOLOGIES (ICEIT), 2017, Rabat, Morocco. **2017 International Conference on Electrical and Information Technologies (ICEIT)**. Rabat, Morocco: IEEE, 2017. p. 1–5. Disponível em: <http://ieeexplore.ieee.org/document/8255225/>. Acesso em: 26 maio 2023.

DA COSTA, Clayton H. *et al.* A Comparison of Machine Learning-Based Methods for Fault Classification in Photovoltaic Systems. *In: 2019 IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE - LATIN AMERICA (ISGT LATIN AMERICA)*, 2019, Gramado, Brazil. **2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)**. Gramado, Brazil: IEEE, 2019. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/8895279/>. Acesso em: 26 maio 2023.

DE BENEDETTI, Massimiliano *et al.* Anomaly detection and predictive maintenance for photovoltaic systems. **Neurocomputing**, [s. l.], v. 310, p. 59–68, 2018.

DJALAB, Aicha Amani *et al.* Robust Method for Diagnosis and Detection of Faults in Photovoltaic Systems Using Artificial Neural Networks. **Periodica Polytechnica Electrical Engineering and Computer Science**, [s. l.], 2020. Disponível em: <https://pp.bme.hu/eecs/article/view/14828>. Acesso em: 27 maio 2023.

ETTAOUIL, Mohamed; LAZAAR, Mohamed; GHANOU, Youssef. Architecture optimization model for the multilayer perceptron and clustering. . **Vol.**, [s. l.], v. 47, 2013.

GÉRON, Aurélien. **Hands-On: Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 3. ed. California: O'Reilly Media, 2022.

GHAFFARZADEH, Navid; AZADIAN, Ahmad. A Comprehensive Review and Performance Evaluation in Solar (PV) Systems Fault Classification and Fault Detection Techniques. [s. l.], v. 4, n. Journal of Solar Energy Research, p. 252–272, 2019.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge, Mass: The MIT press, 2016. (Adaptive computation and machine learning).

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. New Jersey: Pearson Prentice Hall, 2009.

IRENA. Global landscape of renewable energy finance 2023. [s. l.], 2023.

KINGMA, Diederik P.; BA, Jimmy. Adam: A Method for Stochastic Optimization. [s. l.], 2015.

KUKAČKA, Jan; GOLKOV, Vladimir; CREMERS, Daniel. **Regularization for Deep Learning: A Taxonomy**. [S. l.]: arXiv, 2017. Disponível em: <http://arxiv.org/abs/1710.10686>. Acesso em: 9 out. 2023.

LAZZARETTI, André Eugênio *et al.* A Monitoring System for Online Fault Detection and Classification in Photovoltaic Plants. **Sensors**, [s. l.], v. 20, n. 17, p. 4688, 2020.

MAIOROV, Vitaly; PINKUS, Allan. Lower bounds for approximation by MLP neural networks. **Neurocomputing**, [s. l.], v. 25, n. 1–3, p. 81–91, 1999.

MCCULLOCH, Warren S.S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. [s. l.], p. 19, 1943.

MCKINNEY, Wes *et al.* Data structures for statistical computing in python. **Proceedings of the 9th Python in Science Conference**, [s. l.], v. 445, p. 51 a 56, 2010.

MELLIT, Adel; KALOGIROU, Soteris. **Handbook of Artificial Intelligence Techniques in Photovoltaic Systems**. [S. l.]: Elsevier, 2022. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/C20190009600>. Acesso em: 14 jul. 2023.

MICHELUCCI, Umberto. **Applied Deep Learning with TensorFlow 2: Learn to Implement Advanced Deep Learning Techniques with Python**. Berkeley, CA: Apress, 2022. Disponível em: <https://link.springer.com/10.1007/978-1-4842-8020-1>. Acesso em: 16 fev. 2024.

MOHAPATRA, A.; NAYAK, B. K.; MOHANTY, K. B. Comparative study on single diode photovoltaic module parameter extraction methods. *In*: 2013 INTERNATIONAL CONFERENCE ON POWER, ENERGY AND CONTROL (ICPEC), 2013, Sri Rangalatchum Dindigul. **2013 International Conference on Power, Energy and Control (ICPEC)**. Sri Rangalatchum Dindigul: IEEE, 2013. p. 30–34. Disponível em: <http://ieeexplore.ieee.org/document/6527619/>. Acesso em: 5 set. 2023.

ONS. **Portal de Dados Abertos do ONS**. [S. l.], 2024. Disponível em: <https://dados.ons.org.br/>. Acesso em: 8 fev. 2024.

ONS. **Relatório Anual 2022**. Rio de Janeiro: ONS - Operador Nacional do Sistema, 2022.

PAULI VIRTANEN *et al.* SciPy 1.0: fundamental algorithms for scientific computing in Python. **Nature Methods**, [s. l.], v. 17, p. 261–272, 2020.

PEDREGOSA, Fabian *et al.* Scikit-learn: Machine Learning in Python. **Scikit-learn: Machine Learning in Python**, [s. l.], v. 12, p. 2825–2830, 2011.

RAIMUNDO, R *et al.* Power generation by unhealthy photovoltaic modules. **CIGRE SCIENCE & ENGINEERING**, [s. l.], n. 28, p. 1–11, 2023.

RAO, Sunil; SPANIAS, Andreas; TEPEDELENLIOGLU, Cihan. Solar Array Fault Detection using Neural Networks. *In*: 2019 IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL CYBER PHYSICAL SYSTEMS (ICPS), 2019, Taipei, Taiwan. **2019 IEEE International Conference on Industrial Cyber Physical Systems (ICPS)**. Taipei, Taiwan: IEEE, 2019. p. 196–200. Disponível em: <https://ieeexplore.ieee.org/document/8780208/>. Acesso em: 26 maio 2023.

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

RUMELHART, David; HINTON, Geoffrey; WILLIAMS, Ronald. **Learning internal representations by error propagation**. La Jolla, California: University of California, 1985.

SABRI, Nassim; TLEMÇANI, Abdelhalim; CHOUDER, Aissa. Monitoring Tool for Stand-Alone Photovoltaic System Using Artificial Neural Network. *In*: HATTI, Mustapha

(org.). **Renewable Energy for Smart and Sustainable Cities**. Cham: Springer International Publishing, 2019. (Lecture Notes in Networks and Systems). v. 62, p. 114–121. Disponível em: http://link.springer.com/10.1007/978-3-030-04789-4_12. Acesso em: 26 maio 2023.

SNOEK, Jasper; LAROCHELLE, Hugo; ADAMS, Ryan P. **Practical Bayesian Optimization of Machine Learning Algorithms**. [S. l.]: arXiv, 2012. Disponível em: <http://arxiv.org/abs/1206.2944>. Acesso em: 29 set. 2023.

VIEIRA, Romênia Gurgel. **Aplicação de Técnicas de Inteligência Artificial para Identificação de Falhas em Módulos Fotovoltaicos**. 2021. 118 f. - Universidade Federal do Rio Grande do Norte, Natal, RN, 2021.

VILLALVA, Marcelo Gradella; GAZOLI, Jonas Rafael. **Energia Solar Fotovoltaica – Conceitos e Aplicações - Sistemas Isolados e Conectados à Rede**. 2. ed. [S. l.]: Editora Érica, 2012.

VILLALVA, M.G.; GAZOLI, J.R.; FILHO, E.R. Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays. **IEEE Transactions on Power Electronics**, [s. l.], v. 24, n. 5, p. 1198–1208, 2009.

ANEXOS

PRODUÇÃO TÉCNICA E CIENTÍFICA

BEZERRA, Hugo Everaldo Salvador Bezerra *et al.* Comparison of multilayer perceptron neural network architecture in photovoltaic plants fault classification. **Concilium**, v. 23, n. 20, p. 523–536, 2023.