

UNIVERSIDADE FEDERAL DA PARAÍBA  
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



Simulação e Classificação de Falhas no Lado  
CC de Sistemas Fotovoltaicos

José Leandro da Silva

João Pessoa  
Agosto - 2025

JOSÉ LEANDRO DA SILVA

## **Simulação e Classificação de Falhas no Lado CC de Sistemas Fotovoltaicos**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito final para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Yuri Percy Molina Rodriguez

João Pessoa - PB

2025

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

S586s Silva, José Leandro da.

Simulação e classificação de falhas no lado CC de sistemas fotovoltaicos / José Leandro da Silva. - João Pessoa, 2025.

58 f. : il.

Orientação: Yuri Percy Molina Rodriguez.  
Dissertação (Mestrado) - UFPB/CEAR.

1. Energia fotovoltaica. 2. Sistemas fotovoltaicos.  
3. Usinas Fotovoltaica - Comissionamento. 4.  
Classificação de falhas. 5. Classificação multiclasse.  
I. Rodriguez, Yuri Percy Molina. II. Título.

UFPB/BC

CDU 620.91(043)

**UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB**  
**CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA – PPGE**

A Comissão Examinadora, abaixo assinada, aprova a Dissertação  
**SIMULAÇÃO E CLASSIFICAÇÃO DE FALHAS NO LADO CC DE SISTEMAS  
FOTOVOLTAICOS**

Elaborada por  
**JOSÉ LEANDRO DA SILVA**

como requisito parcial para obtenção do grau de  
**Mestre em Engenharia Elétrica.**

**COMISSÃO EXAMINADORA**



---

**PROF. DR. YURI PERCY MOLINA RODRIGUEZ**  
Orientador – UFPB



---

**PROF. DR. JUAN MOISES MAURÍCIO VILLANUEVA**  
Examinador Interno – UFPB



---

**PROF. DR. FRANKLIN MARTINS PEREIRA PAMPLONA**  
Examinador Externo – IFPB

# Agradecimentos

Inicialmente, quero agradecer a Deus por toda a sabedoria concedida durante essa caminhada.

Aos meus pais, José Geraldo e Maria Aparecida, que estiveram presentes em toda a minha trajetória, não apenas no mestrado, mas na vida, apoiando-me sem querer nada em troca, apenas por amor.

Agradeço à minha esposa e ao meu filho, por servirem como suporte e combustível nos momentos mais difíceis ao longo desses dois anos de mestrado, e aos meus irmãos, por sempre compreenderem e me incentivarem a continuar estudando.

Agradeço ao meu orientador, Yuri Molina, pelos ensinamentos, pela compreensão e pela ajuda em todo o processo de desenvolvimento da dissertação.

Agradeço também ao apoio de todos os meus amigos que, de alguma forma, contribuíram para essa conquista, em especial a João Victor, José Marlon e seus pais, Carla e Paulo, por todo o suporte e acolhimento em João Pessoa - PB.

Agradeço a toda a equipe do Laboratório de Eficiência Energética pelo companheirismo ao longo dessa caminhada.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Programa de Mestrado e Doutorado Acadêmico para Inovação (MAI/DAI) pelo apoio à realização desta pesquisa.

Por fim, agradeço a todos aqueles que contribuíram nesse processo tão importante da minha vida.

# Resumo

No presente trabalho, é apresentado um método para a classificação de falhas no lado de corrente contínua em usinas fotovoltaicas, utilizando um modelo de simulação desenvolvido no Matlab/Simulink 2023b e um algoritmo de classificação implementado em Python. A metodologia proposta baseia-se na extração de características das curvas corrente-tensão e potência-tensão para classificar falhas que impactam diretamente a eficiência energética e a segurança das instalações fotovoltaicas. Para validação do método, foram desenvolvidos dois modelos de usinas fotovoltaicas: um com uma string e outro com três strings, simulando diferentes condições ambientais e operacionais. Os dados gerados totalizaram 3.712 amostras para o sistema com uma string e 4.640 para o modelo com três strings, sendo divididos em três subconjuntos e, posteriormente, separados aleatoriamente em 70% para treinamento e 30% para teste. As falhas foram rotuladas em ambas as configurações. No sistema com uma string, foram atribuídos os rótulos: 0 (condição normal), 1 (sombreamento), 2 (curto-circuito) e 3 (falha no conector). No modelo com três strings, foi adicionado o rótulo 4 (circuito aberto). O método proposto utiliza técnicas de classificação multiclasse, aplicando as abordagens One Versus Rest e One Versus One. Nos testes realizados, o método alcançou acurácia de 100% na classificação das falhas para ambas as técnicas. No sistema com uma string, esse desempenho foi obtido com 704 amostras; já no modelo com três strings, a mesma taxa de acerto foi atingida com 2.480 amostras. Esses resultados demonstram a eficácia da abordagem desenvolvida, que contribui de forma significativa para o diagnóstico de falhas em usinas fotovoltaicas, promovendo maior confiabilidade e eficiência nas atividades de operação e manutenção, além de oferecer suporte a profissionais da área e empresas do setor.

**Palavras-chave:** Energia Fotovoltaica, Classificação de Falhas, Classificação Multiclasse, Comissionamento de Usinas Fotovoltaica, Curvas I-V e P-V, Aprendizado de Máquina.

# Abstract

In this work, a method is presented for classifying faults in the direct current side of photovoltaic power plants, using a simulation model developed in Matlab/Simulink 2023b and a classification algorithm implemented in Python. The proposed methodology is based on the extraction of features from current–voltage and power–voltage curves to classify faults that directly affect the energy efficiency and safety of photovoltaic installations. For method validation, two photovoltaic plant models were developed: one with a single string and another with three strings, simulating different environmental and operational conditions. The generated data totaled 3,712 samples for the single-string system and 4,640 for the three-string model, which were divided into three subsets and subsequently split randomly into 70% for training and 30% for testing. Faults were labeled in both configurations. In the single-string system, the assigned labels were: 0 (normal condition), 1 (shading), 2 (short circuit), and 3 (connector failure). In the three-string model, label 4 (open circuit) was added. The proposed method employs multiclass classification techniques, applying the One Versus Rest and One Versus One approaches. In the tests performed, the method achieved 100% accuracy in fault classification for both techniques. In the single-string system, this performance was obtained with 704 samples, while in the three-string model, the same accuracy was reached with 2,480 samples. These results demonstrate the effectiveness of the developed approach, which significantly contributes to fault diagnosis in photovoltaic power plants, promoting greater reliability and efficiency in operation and maintenance activities, in addition to providing support to professionals and companies in the sector.

**Keywords:** Fotovoltaic Energy, Fault Classification, Multiclass Classification, Photovoltaic Power Plant Commissioning, I–V and P–V Curves, Machine Learning.

# Lista de ilustrações

Figura 1 –	Projeção de Participação por Fonte 2031. . . . .	12
Figura 2 –	Fluxograma para Análise Bibliométrica. . . . .	17
Figura 3 –	Falhas no Lado de Corrente Contínua. . . . .	30
Figura 4 –	Configuração de Falhas. . . . .	32
Figura 5 –	Dados Extraídos da Curva I-V e P-V . . . . .	34
Figura 6 –	Fluxograma do Algoritmo do Método Utilizado para Obtenção dos Dados da Curva I-V. . . . .	35
Figura 7 –	Esquema do Modelo com 1 String. . . . .	44
Figura 8 –	Esquema do Modelo com 3 String. . . . .	45
Figura 9 –	Modo de Implementação das Falhas no Matlab/Simulink. . . . .	47
Figura 10 –	Fluxograma do Algoritmo em Python. . . . .	49
Figura 11 –	Comparação das Condições Normais e de Falhas. . . . .	50
Figura 12 –	OVR - Matriz de Confusão 1 String . . . . .	52
Figura 13 –	OVO - Matriz de Confusão 1 String . . . . .	52
Figura 14 –	OVR - Matriz de Confusão 3 String . . . . .	53
Figura 15 –	OVO - Matriz de Confusão 3 String . . . . .	54



# Lista de tabelas

Tabela 1 – Palavras chave, período anual e quantitativo de artigos. . . . .	16
Tabela 2 – Características de <i>UFVs</i> : Microgeração e Minigeração Distribuída. . .	26
Tabela 3 – Exemplo do banco de dados com diferentes irradiância e temperatura de 20°C. . . . .	36
Tabela 4 – Tempo total para construção do banco de dados considerando os tipos de falha e a quantidade de amostras por configuração. . . . .	36
Tabela 5 – Comparação entre o One Versus One ( <i>OVO</i> ) e One Versus Rest ( <i>OVR</i> ). . . . .	41
Tabela 6 – Exemplo de Matriz de Confusão. . . . .	42
Tabela 7 – Parâmetros do Módulo Fotovoltaico . . . . .	45
Tabela 8 – Parâmetros do Diodo de Bypass . . . . .	46
Tabela 9 – Métricas de desempenho para configuração com 1 String. . . . .	51
Tabela 10 – Métricas de desempenho para configuração com 3 String. . . . .	53
Tabela 11 – Tempo de treinamento, em milissegundos, para diferentes volumes de amostras. . . . .	54

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>1.1</b>	<b>Objetivos</b>	<b>13</b>
1.1.1	Objetivo Geral	13
1.1.2	Objetivos Específicos	14
<b>1.2</b>	<b>Contribuição do Trabalho</b>	<b>14</b>
<b>1.3</b>	<b>Organização do Trabalho</b>	<b>15</b>
<b>2</b>	<b>ESTADO DA ARTE</b>	<b>16</b>
<b>2.1</b>	<b>Revisão Bibliométrica</b>	<b>16</b>
<b>2.2</b>	<b>Revisão Sistemática</b>	<b>17</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>25</b>
<b>3.1</b>	<b>Usinas Fotovoltaicas</b>	<b>25</b>
3.1.1	Aplicação das Usinas Fotovoltaicas	26
3.1.2	Problemas em Usinas Fotovoltaica	27
3.1.3	Técnicas de Comissionamento	28
<b>3.2</b>	<b>Falhas em Usinas Fotovoltaicas</b>	<b>30</b>
3.2.1	Falha de Circuito Aberto	31
3.2.2	Falha Curto Circuito Linha-Linha	31
3.2.3	Falha de Sombreamento	31
3.2.4	Falha nos Conectores	31
3.2.5	Impacto das Falhas em Usinas Fotovoltaicas	32
<b>3.3</b>	<b>Classificação das Falhas</b>	<b>33</b>
3.3.1	Criação do Banco de Dados	34
3.3.2	Tratamento de Dados	36
3.3.3	Classificação Multiclasse	37
3.3.3.1	One versus Rest (OVR)	38
3.3.3.2	One versus One (OVO)	39
<b>3.4</b>	<b>Métricas de Avaliação</b>	<b>40</b>
3.4.1	Acurácia	40
3.4.2	Precisão	41
3.4.3	Sensibilidade	41
3.4.4	Matriz de Confusão	42
<b>4</b>	<b>MÉTODO PROPOSTO</b>	<b>43</b>
<b>4.1</b>	<b>Modelo dos Sistemas Simulados</b>	<b>43</b>

4.1.1	Modelo 1 String . . . . .	43
4.1.2	Modelo 3 String . . . . .	44
<b>4.2</b>	<b>Descrição e Parâmetros . . . . .</b>	<b>45</b>
<b>4.3</b>	<b>Implementação de Falhas . . . . .</b>	<b>46</b>
4.3.1	Circuito Aberto . . . . .	46
4.3.2	Sombreamento Parcial . . . . .	47
4.3.3	Curto Linha-Linha . . . . .	48
4.3.4	Falha Conector . . . . .	48
<b>4.4</b>	<b>Algoritmo do Método Proposto . . . . .</b>	<b>49</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES . . . . .</b>	<b>50</b>
<b>5.1</b>	<b>Resultado da Classificação Utilizando 1 String . . . . .</b>	<b>51</b>
<b>5.2</b>	<b>Resultado da Classificação Utilizando 3 String . . . . .</b>	<b>52</b>
<b>6</b>	<b>CONCLUSÃO . . . . .</b>	<b>55</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>57</b>

# 1 Introdução

Segundo dados da Empresa de Pesquisa Energética (EPE, 2023), o consumo de energia elétrica no Brasil registrou um aumento de aproximadamente 13,19% nos últimos cinco anos. Esse crescimento está diretamente relacionado ao avanço econômico do país e impulsionado, principalmente, pelo aumento no consumo dos setores residencial e industrial.

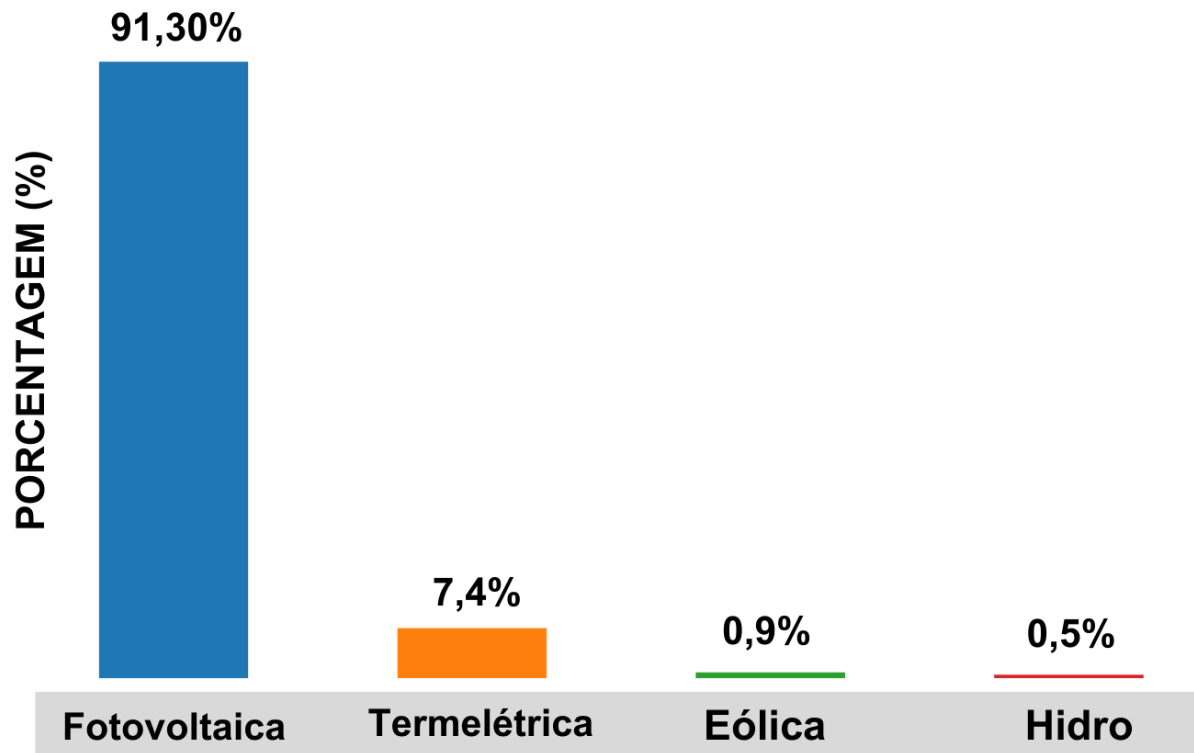
A diversificação da matriz energética brasileira tem desempenhado um papel fundamental nesse processo, a integração de fontes renováveis ganhando destaque, especialmente a Geração Fotovoltaica (*FV*). Os incentivos governamentais para a adoção de energias renováveis também contribuíram significativamente para essa diversificação. Esses incentivos incluem programas de subsídios, redução de impostos em projetos sustentáveis e políticas que estimulam a eficiência energética, utilizando fontes de menor impacto ambiental (EPE, 2023).

De acordo com a Agência Nacional de Energia Elétrica (ANEEL, 2025), o Brasil alcançou uma potência fiscalizada de 208.930,5 Mega Watts (*MW*) em janeiro de 2025, considerando usinas em operação e projetos outorgados em fase de construção. Dentro dessa capacidade total, a fonte hídrica representa cerca de 49,02% da matriz, enquanto a *FV* contribui com uma participação expressiva de 15,57% (ANEEL, 2025).

Nos últimos dez anos, a *FV* no Brasil apresentou um crescimento notável. Segundo dados da (EPE, 2023), a geração total passou de 16 Giga Watt Hora (*GWh*) em 2014 para aproximadamente 50.632,9 *GWh* em 2024. Esse avanço foi impulsionado por diversos fatores, com destaque a redução dos custos das tecnologias fotovoltaicas e os incentivos governamentais voltados à instalação de sistemas com fontes renováveis, buscando mitigar impactos ambientais.

Segundo o Plano Nacional de Expansão de Energia (PDE, 2031), conforme apresentado na Fig. 1, a projeção de participação na geração de energia proveniente de fontes renováveis, destacando-se a *FV* com 91,3 % de capacidade instalada. Embora a *FV* apresente diversos benefícios, a eficiência dos módulos fotovoltaicos é relativamente baixa e diversas Usinas Fotovoltaicas (*UFV*) têm apresentado falhas. Contudo, é necessário um bom desenvolvimento do projeto, execução, Operação e Manutenção (*O&M*) das usinas para ter um melhor desempenho e melhorar a vida útil dos equipamentos.

Figura 1 – Projeção de Participação por Fonte 2031.



Fonte: PDE, 2031.

As falhas apresentadas em *UFV* podem ser classificadas como física, ambiental e elétrica (HOJABRI *et al.*, 2022). Para mitigar essas falhas, fica evidente a necessidade do monitoramento, padronização e classificação desses problemas que afetam a eficiência e a viabilidade financeira desses sistemas. No Brasil, a (NBR-16274, 2014) recomenda a execução de ensaios rigorosos para verificar as condições das instalações.

Nesse contexto, o comissionamento desempenha um papel estratégico, envolvendo ações como verificações e ensaios realizados tanto antes quanto após a energização dos sistemas. Esse processo visa assegurar a conformidade das instalações, identificar potenciais erros, danos nos equipamentos e falhas operacionais, além de promover ajustes nos parâmetros de operação e fortalecer as práticas de prevenção e detecção de falhas (GOKGOZ *et al.*, 2023).

Apesar de muitos investidores considerarem o comissionamento como um gasto desnecessário, sua utilização traz benefícios significativos, garante a confiabilidade, a segurança das usinas, contribuindo para a sustentabilidade técnica e econômica dos sistemas fotovoltaicos (GOKGOZ *et al.*, 2023).

O diagnóstico de falhas em *UFV* é comumente realizado por meio da análise das curvas Corrente-Tensão ( $I - V$ ) e Potência-Tensão ( $P - V$ ). Essa abordagem permite a identificação de parâmetros críticos, como a corrente de curto-circuito ( $I_{sc}$ ), tensão de circuito aberto ( $V_{oc}$ ), corrente no ponto de máxima potência ( $I_{m\acute{a}x}$ ), tensão no ponto de

máxima potência ( $V_{\text{máx}}$ ) e potência máxima ( $P_{\text{máx}}$ ) em módulos individuais ou arranjos conectados em série ou paralelo.

Essas informações são fundamentais para avaliar a integridade dos módulos, facilitando a detecção de falhas que podem comprometer a eficiência das usinas e representar riscos significativos, como incêndios (HOJABRI *et al.*, 2022). Tais falhas contribuem diretamente para a redução da potência de saída, impactando negativamente o retorno financeiro, uma vez que este está diretamente relacionado à energia gerada na saída do inversor dos sistemas fotovoltaicos.

Diversos estudos na literatura abordam a detecção de falhas em usinas fotovoltaicas, identificando aquelas que mais impactam negativamente esses sistemas. Além disso, diferentes técnicas têm sido empregadas para detectar e classificar tais falhas. No entanto, a maioria dos trabalhos não considera a interligação dessas falhas com o processo de comissionamento, nem aborda a generalização de parâmetros ou de condições ambientais adversas, e tampouco utiliza técnicas de classificação multiclasse.

Neste contexto, o presente trabalho tem como objetivo simular diferentes condições de falhas em sistemas fotovoltaicos, considerando uma ampla gama de valores de temperatura e irradiância. Para a tarefa de classificação, são empregadas estratégias multiclasse responsáveis por decompor o problema em subproblemas binários em conjunto com o classificador *XGBClassifier*, que realiza a identificação das falhas. Essa abordagem visa construir um banco de dados mais robusto e abrangente, incorporando as influências ambientais que afetam o desempenho dos módulos fotovoltaicos, além de utilizar uma técnica de classificação adequada ao problema.

O banco de dados gerado será utilizado para validar o método de classificação de falhas no lado de Corrente Contínua (*CC*), permitindo uma análise detalhada e precisa das condições operacionais do sistema. A proposta busca oferecer maior confiabilidade no diagnóstico de falhas, contribuindo para a eficiência na operação e manutenção de *UFV*.

## 1.1 Objetivos

Nesta seção será apresentado os objetivos, gerais e específicos, do presente trabalho.

### 1.1.1 Objetivo Geral

O presente trabalho tem como objetivo geral simular um sistema fotovoltaico sob diferentes condições de irradiância e temperatura. Além disso, busca-se construir um banco de dados contendo as características das curvas I-V e P-V em condições normais e de falhas no lado de corrente contínua, com diferentes volumes de amostras, servindo de base para a aplicação de uma técnica de classificação multiclasse.

### 1.1.2 Objetivos Específicos

Os objetivos específicos são:

- Simular um sistema fotovoltaico em condições normais e de falhas no lado de corrente contínua.
- Criar uma metodologia para obtenção de característica das curva  $I - V$  e  $P - V$  e construção do banco de dados com diferentes valores de irradiância e temperatura.
- Aplica uma metodologia de classificação de falhas multiclasse e validar com o banco de dados.
- Relacionar a detecção e classificação de falhas com o comissionamento e trabalho no campo desenvolvido por profissionais da área.

## 1.2 Contribuição do Trabalho

As principais contribuições deste trabalho são:

- Proposta de uma metodologia de classificação de falhas baseada em modelos multiclasse, adequada para cenários que demandam a distinção entre mais de dois tipos de falhas.
- Desenvolvimento de uma técnica robusta de classificação de falhas fundamentada em aprendizado de máquina, obtendo uma acurácia média superior a 99,45%.
- Aplicação em condições variadas de irradiância e temperatura, considerando diferentes condições ambientais, o que amplia sua aplicabilidade e robustez do método.
- Elaboração de uma metodologia para criação de banco de dados por meio da extração de características das curvas  $I - V$  e  $P - V$ . Essa abordagem é integrada às práticas de campo realizadas na etapa de comissionamento, fornecendo suporte para operação e manutenção.

No que diz respeito à publicação do presente trabalho, tem-se:

- Fault Classification in Photovoltaic Power Plants Using Machine Learning, publicado na Energies, seção F5-Artificial Intelligence and Smart Energy, em setembro de 2025. (Quartil Q1). Doi: 10.3390/en18174681

## 1.3 Organização do Trabalho

A organização do presente trabalho é descrita a seguir:

No capítulo 2, é apresentada uma revisão da literatura sobre a temática abordada, acompanhada da metodologia de pesquisa para obtenção do portfólio utilizado como referência.

No capítulo 3, é desenvolvida a fundamentação teórica. São discutidos tópicos relacionados às usinas fotovoltaicas, falhas em suas instalações e o modelo de classificação utilizado.

No capítulo 4, são apresentados os modelos do sistema simulado, a descrição dos parâmetros e o modo de implementação das falhas.

Os resultados obtidos, acompanhados da análise e discussão das condições simuladas, são apresentados no capítulo 5.

Por fim, no capítulo 6, são discutidos os resultados das simulações, os impactos das condições de falhas, e apresentadas conclusões, além de sugestões para trabalhos futuros.



## 2 Estado da Arte

Este capítulo tem como objetivo apresentar uma revisão do estado da arte relacionada à temática de comissionamento e falhas em usinas fotovoltaicas. Todo o levantamento bibliográfico foi realizado utilizando o banco de dados Google Scholar, que abrange as principais revistas da área de pesquisa.

### 2.1 Revisão Bibliométrica

Neste capítulo, realizamos uma revisão bibliométrica a fim de identificar o avanço tecnológico e tendências futuras, buscando as publicações referente ao tema, bem como as aplicações das técnicas de comissionamento, detecção e classificação de falhas. Além disso, tem como objetivo permitir que essa metodologia seja replicada.

Inicialmente, foi feito uma busca no banco de dados Google Scholar gerando uma total de 2.180 artigos, gerando portfólio bruto, conforme a Tab. 1.

Tabela 1 – Palavras chave, período anual e quantitativo de artigos.

Palavras-Chave	Período Anual	Quantidade de Artigos
solar plants AND commissioning	2019 - 2024	200
O&M AND commissioning AND fotovoltaic systems	2019 - 2024	200
fault detection AND commissioning AND fotovoltaic	2019 - 2024	200
methods AND solar system AND commissioning	2019 - 2024	200
commissioning AND fotovoltaic systems	2014 - 2024	980
comissionamento AND sistemas fotovoltaicos	2019 - 2024	200
fotovoltaic systems	2019 - 2024	200

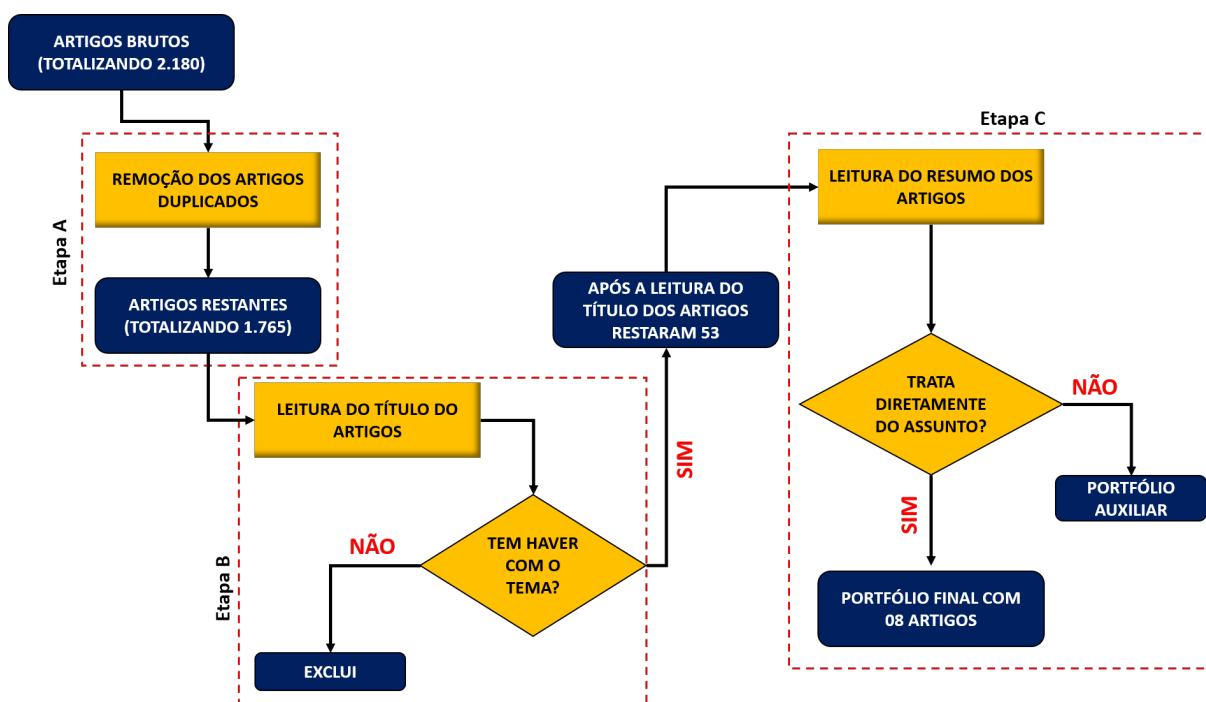
Fonte: Elaborado pelo autor.

A Tab. 1 apresentada o modo que foram utilizadas as combinações de palavras chaves e pesquisas com o auxílio do software Publish or Perish. Essa ferramenta permite pesquisar em diversos bancos de dados, utilizando palavras chaves, conectivos lógicos, data específica, nome dos autores, dentre outros, obtendo o portfólio bruto.

Na Fig. 2 será apresentado o fluxograma para verificação, mostrando o passo a passo do método e modo de escolha dos artigos mais relevantes para a pesquisa. A configuração da metodologia utilizada, para escolha do portfólio, foi dividido em três etapas: A, B e C.

Na etapa A, é realizado uma remoção dos artigos duplicados, uma vez que o Google Scholar busca os artigos em diversos bancos de dados e, conseqüentemente, gera artigos idênticos. Nessa etapa foi utilizado o ZOTERO, um software gratuito para gerenciamento de referência que reconhece os artigos duplicados e permite excluí-los de forma mais rápida.

Figura 2 – Fluxograma para Análise Bibliométrica.



Fonte: Elaborado pelo autor.

Na etapa B, após a remoção dos artigos duplicados, é realizado a leitura do título dos artigos restantes para verificar se tem relevância com o que busca-se na pesquisa. Essa etapa é a mais demorada, uma vez que você precisa realizar a leitura dos títulos e verificar se o artigo é relevante para a pesquisa, se não for deve remover.

Por fim, na etapa C, deve-se realizar a leitura do resumo a fim de verificar se trata diretamente com o assunto, tornando assim uma referência para dissertação. É importante salientar que os trabalhos nessa etapa são todos importantes, porém pode-se utilizar como auxiliar os que não tratam diretamente do assunto.

Após toda análise dos artigos, verificou-se que existe pouca publicação sobre a temática analisada, uma vez que restaram apenas 08 trabalhos, onde são artigos que se relacionam diretamente com o tema.

Logo, é notória a importância de novas pesquisas sobre esse assunto, considerando que há poucos estudos na área, o que torna a investigação inovadora. Além disso, eficiência, prevenção de falhas e comissionamento em *UFV* estão diretamente interligadas ao retorno do investimento em projetos de pequenas, médias e, principalmente, grandes usinas.

## 2.2 Revisão Sistemática

O comissionamento e classificação de falhas em *UFV* têm tido destaque nos últimos anos, visto que sua implementação em paralelo com boas práticas de *O&M* aumenta desempenho e eficiência dos sistemas. Contudo, conforme apresentado na seção 2.1 não

encontram-se muitas pesquisas científicas a acerca do tema específico abrindo uma gama de possibilidades de desenvolvimento de trabalhos.

A apresentação da revisão sistemática utilizada como base será mostrado na seguinte sequência: artigos relacionados na pesquisa, escolhidos conforme descrito no fluxograma da Fig. 2 e artigos relacionados a classificação de falhas.

Em (ZHU, 2019), foi proposto um método adaptativo para a detecção de curvas  $I - V$  em módulos fotovoltaicos, visando melhorar a precisão e a velocidade do processo de traçar curvas. O principal objetivo foi comparar diferentes topologias de conversores DC-DC, como os conversores Buck, Boost e Buck-Boost, e propor um método adaptativo que ajusta o ciclo de trabalho dinamicamente durante o processo. O estudo foi simulado no Matlab/Simulink e os resultados mostraram que o método adaptativo melhorou significativamente a precisão nas regiões críticas da curva, especialmente nas regiões de tensão e potência, ao mesmo tempo em que reduziu o tempo de traçar para menos de um segundo. Apesar dos resultados promissores, o estudo destacou a necessidade de controle mais refinado sobre o ciclo de trabalho e a complexidade adicional da implementação como lacunas a serem abordadas em futuras pesquisas.

Em (MOHAMMADREZA *et al.*, 2020), foi analisada a viabilidade do uso de termografia infravermelha aérea para a detecção rápida e de baixo custo de anomalias em *UFV* de grande escala. O principal objetivo foi comparar diferentes sistemas de termografia para avaliar o impacto na eficiência da detecção de falhas e na redução dos custos de operação e manutenção. O estudo foi conduzido em quatro usinas localizadas no nordeste do Brasil, utilizando drones equipados com câmeras de termografia infravermelha e câmeras *RGB*, além de testar dois métodos de análise de falhas: em tempo real e após voo. Os resultados indicaram que a combinação de câmeras *RGB* com a análise após voo apresentou o melhor desempenho. Entre os principais problemas detectados estavam módulos quebrados, strings e substrings desconectadas, além de falhas causadas por sujeira e vegetação. Embora os resultados tenham sido promissores, o estudo identificou algumas lacunas, como a necessidade de inspeção em solo. Além disso, as condições ambientais, como vento e reflexos solares, influenciaram a qualidade das imagens capturadas, representando um desafio para a precisão da detecção.

Em (CASSINI *et al.*, 2022), foi desenvolvida uma metodologia para corrigir a corrente de curto circuito ( $I_{sc}$ ) medida durante o comissionamento a frio de *UFV*, considerando o acúmulo de sujeira nos módulos. O objetivo foi ajustar os dados elétricos para refletir o desempenho dos módulos em condições limpas, evitando interpretações errôneas sobre falhas no sistema. O estudo foi realizado em duas usinas em Minas Gerais, localizadas em Januária, clima semiárido, e Paracatu, clima equatorial), utilizando o "Soiling Ratio" ( $SR_{ratio}$ ), que compara a  $I_{sc}$  medida em módulos sujos com a de módulos limpos. A correção dos dados com base nesse fator melhorou a precisão da avaliação, mostrando

que sem esse ajuste, as variações poderiam ser erroneamente atribuídas a falhas. Embora o estudo tenha sido eficaz, foram identificadas limitações, como a necessidade de inspeções visuais frequentes e a influência das condições ambientais. Isso sugere a importância de métodos automatizados e contínuos para melhorar a precisão das medições e reduzir a necessidade de monitoramento manual.

(CARDINALE *et al.*, 2022) realizaram um estudo comparativo quantitativo entre três técnicas de detecção de falhas em módulos fotovoltaicos: Termografia Infravermelha (*IRT*), Inspeção visual (*VI*) e Análise Elétrica (*EA*). O objetivo foi comparar a eficácia dessas técnicas na detecção de condições sub ótimas, como sombreamento parcial, sujidade e falhas elétricas, visando melhorar a manutenção de Sistemas Fotovoltaicos. O estudo revelou que a inspeção visual foi a mais eficaz na detecção de sujidade e sombreamento parcial, atingindo 100% de eficácia. Já a termografia infravermelha e a análise elétrica apresentaram eficácias de 78% e 73%, respectivamente. Os resultados indicam que nenhuma das técnicas sozinha é capaz de detectar todas as falhas de maneira completa, sugerindo que uma combinação entre inspeção visual com termografia ou análise elétrica é necessária para maximizar a detecção. As limitações incluem a incapacidade da inspeção visual de identificar falhas elétricas e a variabilidade na detecção de sujidade tanto na termografia quanto na análise elétrica. O estudo contribui com dados experimentais inéditos para a escolha mais objetiva de técnicas de manutenção, além de sugerir áreas de aprimoramento, como a automação e a integração das técnicas.

Em (SANTOS *et al.*, 2022), foi realizada uma análise sobre os problemas mais comuns em instalações fotovoltaicas de micro e minigeração, identificando suas causas e apresentando formas de preveni-los. O estudo classificou os problemas em três categorias: estruturais, elétricos e de desempenho. Foram utilizados diagramas de Ishikawa para identificar as causas raiz em cada categoria. Entre os problemas estruturais, foram destacadas falhas no dimensionamento da estrutura de suporte e no uso de componentes improvisados. Já os problemas elétricos incluem falhas na equipotencialização, crimpagem inadequada de conectores (*MC4*) e dimensionamento incorreto de condutores, resultando em riscos como incêndios e superaquecimentos. Por fim, os problemas de desempenho frequentemente se devem a azimutes ou inclinações incorretas, sombreamento e sujeira acumulada nos módulos. O estudo propõe que a adoção das normas NBR-16690 e NBR-16274, além de treinamentos adequados para os profissionais envolvidos, são essenciais para prevenir e corrigir essas falhas. Contudo, foi destacada a limitação no uso dessas normas em projetos de micro e minigeração, devido ao custo elevado de alguns equipamentos e à necessidade de mais estudos para adaptar os requisitos normativos a esse tipo de instalação.

Em (PIMENTEL *et al.*, 2022), o estudo identificou como principais causas das falhas estruturais o dimensionamento inadequado da estrutura de suporte e o uso de componentes improvisados. Entre os problemas elétricos, destacaram-se falhas na equipo-

tencialização, crimpagem inadequada de conectores *MC4* e dimensionamento incorreto de condutores, resultando em riscos como superaquecimento e incêndios. Já os problemas de desempenho foram associados a azimutes e inclinações incorretas, sombreamento e acúmulo de sujeira nos módulos. Para abordar essas falhas, o estudo utilizou diagramas de Ishikawa, que permitiram identificar as causas-raiz de cada problema. Como solução, foi proposta a adoção de normas como a NBR-16690 e NBR-16274, além do treinamento adequado de profissionais, visando prevenir falhas e garantir o desempenho ideal dos sistemas. Apesar das contribuições significativas, o método apresentado possui limitações. A aplicação das normas sugeridas pode ser inviabilizada em projetos de micro e minigeração devido ao custo elevado de equipamentos e à necessidade de mais estudos que adaptem os requisitos normativos a esse contexto.

Em (GOKGOZ *et al.*, 2023), foram analisados os desafios enfrentados durante o comissionamento e a operação de usinas fotovoltaicas devido a falhas elétricas, com o objetivo de categorizar e classificar essas falhas para melhorar o diagnóstico e o planejamento de *O&M*. O estudo destacou a falta de padronização na classificação das falhas e a escassez de estudos detalhados sobre falhas elétricas específicas em usinas fotovoltaicas. Embora a classificação proposta de falhas em corrente alternada e corrente contínua facilite a identificação de problemas e a tomada de medidas preventivas, os autores apontaram a necessidade de estudos mais aprofundados sobre as interações entre falhas elétricas e condições ambientais adversas, como tempestades, oscilações de temperatura e problemas de vegetação. Para projetos futuros, foi sugerida a criação de modelos computacionais para examinar as falhas em diferentes cenários, permitindo uma análise mais precisa das causas e efeitos das falhas. Além disso, o desenvolvimento de ferramentas de monitoramento automatizado, criação de ferramentas de documentação completa sobre as falhas e métodos de solução, bem como desenvolvimento de algoritmos de detecção baseados em sinais de medição para antecipar falhas antes que elas ocorram, aumentando a confiabilidade e a eficiência das usinas fotovoltaicas.

(GOKGOZ *et al.*, 2024) investigaram falhas ocorridas durante o comissionamento e operação de sistemas fotovoltaicos, com o objetivo de classificar e modelar essas falhas para aumentar a confiabilidade e otimizar a operação e manutenção das usinas. A metodologia utilizada baseou-se em simulações com o software MATLAB Simulink, modelando falhas como curtos-circuitos, circuitos abertos, falhas em inversores e módulos fotovoltaicos, tanto no lado corrente alternada quanto no lado de corrente contínua. Essas falhas foram analisadas quanto ao impacto em corrente e tensão no sistema. Os resultados mostraram que as falhas no lado de corrente alternada, especialmente curtos circuitos entre fases, causam maiores distorções e aumento de corrente, enquanto falhas no lado corrente contínua afetam menos a produção de energia. A classificação das falhas proposta facilita a identificação e correção rápida de problemas, reduzindo o tempo de inatividade e perdas financeiras. Entre as limitações, o estudo não abordou variáveis ambientais complexas,

como mudanças climáticas, e não incluiu dispositivos de proteção que interromperiam o sistema em falhas severas. Para pesquisas futuras, os autores sugerem o desenvolvimento de sistemas de monitoramento automatizado e algoritmos de detecção precoce para aumentar a eficiência e confiabilidade das usinas fotovoltaicas.

Os artigos que tratam sobre o assunto de classificação são:

Em (COSTA *et al.*, 2019), foi realizada uma comparação entre diferentes métodos baseados em aprendizado de máquina para a classificação de falhas em sistemas fotovoltaicos. O objetivo foi identificar a abordagem mais eficaz na detecção de falhas, como curto-circuito em módulo, falha no rastreamento do ponto de máxima potência (*MPPT*), circuito aberto, sombreamento parcial e degradação, visando melhorar a manutenção e a confiabilidade dos sistemas. O estudo utilizou algoritmos de aprendizado supervisionado, incluindo k-vizinhos mais próximos ( $k-NN$ ), árvores de decisão (*DT*), máquinas de vetores de suporte (*SVM*) e redes neurais artificiais (*ANN*), avaliando suas taxas de acurácia e tempos de treinamento. Os métodos foram testados em um conjunto de dados contendo variáveis como tensão, corrente, temperatura e irradiância, com simulações realizadas no MATLAB e no PSIM. Os resultados indicaram que as redes neurais artificiais (*ANN*) obtiveram a melhor acurácia (99,65%), porém com maior tempo de treinamento, enquanto as máquinas de vetores de suporte (*SVM*) apresentaram desempenho próximo com tempo significativamente menor. O estudo destacou a importância de considerar a complexidade computacional na escolha do modelo e sugeriu a necessidade de experimentos em sistemas reais para validar os achados e otimizar a implementação prática.

Em (BADR *et al.*, 2024), foi proposta uma metodologia baseada em aprendizado de máquina para a identificação de falhas em arranjos fotovoltaicos, visando melhorar a detecção e diagnóstico de falhas comuns nesses sistemas. O estudo classifica as falhas em permanentes (falha de arco, curto circuito linha-linha, falha da unidade de *MPPT* e falha de circuito aberto) e temporárias, sombreamento parcial. Para a identificação das falhas, foram empregados três classificadores de aprendizado de máquina: Árvore de Decisão (*DT*), *KNN* e *SVM*. Além disso, a Otimização Bayesiana foi utilizada para ajustar hiperparâmetros e melhorar a performance dos modelos. A validação foi conduzida por meio de simulações no MATLAB/Simulink e testes experimentais utilizando um arranjo fotovoltaico real. Os resultados mostraram que o modelo baseado em *SVM* com kernel cúbico apresentou a melhor precisão na detecção de falhas 99,78%, enquanto o *SVM* com kernel de Função de Base Radial (*RBF*) alcançou a maior precisão na classificação das falhas 89,84%. Os autores destacam que o método proposto supera abordagens anteriores ao reduzir a necessidade de sensores adicionais e fornecer um diagnóstico mais preciso. Contudo, o artigo aponta algumas limitações, como a necessidade de aprimorar a detecção de falhas híbridas permanentes e temporárias e a influência da localização das falhas nos resultados dos classificadores. Além disso, sugere que futuras pesquisas explorem o

impacto da variabilidade da irradiância e temperatura em diferentes configurações de sistemas fotovoltaicos.

Em (MELIT; KALOGIROU, 2022), foi realizada uma avaliação de métodos de aprendizado de máquina e aprendizado por comitê para diagnóstico de falhas em sistemas fotovoltaicos. O objetivo foi detectar e classificar falhas complexas, como múltiplas falhas simultâneas e falhas com curvas  $I - V$  semelhantes, que não foram amplamente estudadas anteriormente. O estudo utilizou diferentes abordagens, incluindo a análise de curvas  $I - V$  e imagens térmicas, aplicando modelos como  $RN$ ,  $SVM$  e algoritmos de boosting como o XGBoost, LightGBM e CatBoost. Os resultados indicaram que os métodos desenvolvidos alcançaram alta precisão na detecção de falhas de 99%, enquanto a classificação apresentou uma precisão de 81,73%. O estudo destacou que, embora o aprendizado de máquina seja eficiente, a escolha do modelo deve considerar o tempo de computação e a facilidade de implementação para aplicações em tempo real. Como limitação, foi apontada a necessidade de bases de dados mais abrangentes e testes experimentais para validar a aplicabilidade dos métodos em condições reais de operação.

Em (ALSUDI; K, 2023), foi proposta uma abordagem baseada em aprendizado profundo para a detecção, classificação e localização de falhas em  $FV$ . O crescimento acelerado das  $UFV$  e a complexidade da rede elétrica aumentam a dificuldade na identificação e correção de falhas nesses sistemas. Para lidar com esse problema, o estudo testou três tipos de falhas: circuito aberto, curto circuito e sombreamento, utilizando três arquiteturas de redes neurais profundas. O modelo foi implementado no MATLAB/Simulink e analisou dados de corrente nos strings do sistema fotovoltaico. As imagens dos sinais foram processadas e classificadas por Redes Neurais Convolucionais ( $CNN$ ), sendo que a arquitetura ResNet-50 obteve a maior acurácia, atingindo 98,22%. A principal contribuição do estudo é a utilização de aprendizado profundo para aprimorar a detecção e classificação de falhas em tempo real, permitindo uma resposta mais rápida e eficiente na manutenção dos  $FV$ . Entretanto, o artigo não aborda a aplicação em condições climáticas reais nem discute a viabilidade de implementação em larga escala, apontando a necessidade de validações experimentais mais abrangentes.

Em (ALJAFARI *et al.*, 2024), foi proposto um método para a detecção e classificação de falhas em sistemas fotovoltaicos conectados à rede ( $GCPV$ ), abordando desafios como curto circuito, circuito aberto e sombreamento parcial, que impactam a eficiência dos sistemas. A metodologia empregou uma Rede Neural Convolucional Unidimensional ( $1D - CNN$ ) integrada a um sistema de Internet das Coisas ( $IoT$ ) para monitoramento e diagnóstico remoto. O estudo utilizou simulações no MATLAB/Simulink e testes experimentais em um sistema fotovoltaico de 15  $kWp$ , coletando dados de sensores distribuídos estrategicamente para otimizar a análise. Os resultados demonstraram uma precisão de 98,15% na detecção de falhas e 93,12% sob condições adversas, como ataques cibernéticos.

A principal contribuição do trabalho está na robustez da abordagem baseada em aprendizado profundo, que supera métodos convencionais ao garantir diagnósticos mais confiáveis e um monitoramento eficiente via *IoT*. No entanto, o estudo apresenta limitações quanto à generalização do modelo para condições extremas de irradiância e temperatura, indicando a necessidade de aprimoramentos para ampliar sua aplicabilidade a diferentes cenários operacionais.

No artigo de (AMIRI *et al.*, 2024), foi proposta uma metodologia para detecção e diagnóstico de falhas em sistemas fotovoltaicos utilizando um classificador Random Forest (*RF*). O estudo aborda a necessidade de detectar falhas em *FV*, pois problemas como curto circuito, sombreamento e falhas em strings podem comprometer a eficiência energética e a segurança dos sistemas. Para isso, os autores desenvolveram um modelo de detecção em duas etapas: inicialmente, os parâmetros desconhecidos do modelo de um diodo foram extraídos utilizando o algoritmo de otimização Modified Grey Wolf Optimization (*MGWO*). Em seguida, os dados operacionais foram obtidos por meio de co-simulações em PSIM/MATLAB, permitindo a criação de um banco de dados de referência. Dois classificadores RF foram implementados: um para detecção de falhas classificação binária e outro para diagnóstico classificação multiclasse. Os resultados obtidos demonstraram alta precisão, com Erro Médio Quadrático (*RMSE*) de 0.0122 para a extração dos parâmetros do modelo e acurácia de 99,4% na detecção e classificação de falhas, superando modelos como Máquina de Vetores de Suporte (*SVM*), K-Nearest Neighbors (*KNN*) e Redes Neurais (*RN*). Apesar da eficácia do método, o estudo destaca que sua precisão depende da qualidade dos dados utilizados no treinamento dos modelos, sugerindo que futuros trabalhos explorem técnicas de aprendizado profundo para aprimorar a localização exata das falhas.

Em (BOUGOFFA *et al.*, 2024), foi proposta uma metodologia para diagnóstico de falhas em *FV* utilizando redes neurais convolucionais. A identificação precoce de falhas, como curto circuito, circuito aberto, degradação e sombreamento, é essencial para otimizar o desempenho e a confiabilidade dos *FV*. Métodos convencionais de detecção de falhas, baseados em inspeções manuais e algoritmos baseados em regras, são ineficientes e suscetíveis a imprecisões. Para superar essas limitações, a pesquisa empregou um modelo baseado em *CNNs*, capaz de extrair padrões complexos a partir de dados elétricos e ambientais, incluindo tensão, corrente, irradiação e temperatura. O método foi validado utilizando um conjunto de dados provenientes de sistemas *FV* reais, abrangendo diversas condições operacionais e tipos de falhas. O treinamento e a otimização do modelo resultaram em uma acurácia média de 99,7% na detecção e classificação de falhas. Os resultados demonstram a eficácia da abordagem baseada em aprendizado profundo, possibilitando uma identificação mais confiável e automatizada de falhas. No entanto, o estudo não considera a integração de outras fontes de dados, como condições meteorológicas e a orientação dos módulos, o que poderia aprimorar ainda mais a robustez do modelo. Além disso, testes



em campo são necessários para validar a aplicabilidade do método em diferentes cenários operacionais.

Em (SUMILAN *et al.*, 2024), foi analisada a detecção e classificação de falhas elétricas no lado *CC* de sistemas fotovoltaicos, um desafio que não é completamente abordado pelos dispositivos de proteção convencionais. O estudo propôs o uso de classificadores de aprendizado de máquina, como *SVM* e Extreme Gradient Boosting (*XGBoost*), para melhorar a detecção de falhas em pequenos arranjos fotovoltaicos. Além disso, os algoritmos foram otimizados com Bees Algorithm (*BA*) e Particle Swarm Optimization (*PSO*) para aprimorar a precisão na classificação de falhas. A metodologia foi validada em um conjunto experimental de dados reais de corrente, tensão e irradiância, gerados por um sistema fotovoltaico em laboratório. Os resultados mostraram que a otimização com o Bees Algorithm melhorou significativamente o desempenho dos classificadores, tornando-se a abordagem mais eficaz para detecção de falhas. Contudo, o estudo destacou desafios como a necessidade de bases de dados mais amplas e testes em escala real para validar a robustez dos métodos propostos em diferentes condições operacionais.

A revisão bibliográfica e sistemática realizada foi fundamental para delimitar o estudo, ao evidenciar a escassez de pesquisas que integrem o processo de comissionamento em campo com metodologias de aprendizado de máquina aplicadas à classificação multi-classe de falhas sob diferentes condições climáticas. Esse diagnóstico não apenas reforçou a relevância da investigação proposta, como também indicou possibilidades concretas de contribuição técnica, sobretudo na área de operação e manutenção, por meio do aprimoramento da classificação de falhas e da análise do comportamento de usinas fotovoltaicas sob diferentes condições operacionais.

## 3 Fundamentação Teórica

Neste capítulo, é apresentada a fundamentação teórica do trabalho. Inicialmente, é feito um breve histórico sobre as *UFVs*, abordando sua geração, impactos na matriz energética, principais problemas e técnicas de comissionamento. As seções seguintes detalham os tipos de falhas e seus impactos nos sistemas fotovoltaicos, além do processo de criação do banco de dados, tratamento dos dados e a aplicação do método de classificação multiclasse para identificação de falhas.

### 3.1 Usinas Fotovoltaicas

As *UFV* têm ganhado destaque no cenário mundial, principalmente, nos últimos 10 anos. No Brasil, segundo a Agência Nacional de Energia Elétrica (*ANEEL*), conforme estabelecido na Resolução Normativa nº 1.300/2021 (*ANEEL*, 2021), elas podem ser classificadas como microgeração ou minigeração distribuída, de acordo com a potência instalada em quilowatts (*kW*)

A microgeração distribuída é uma central geradora de energia elétrica com potência instalada, em corrente alternada, menor ou igual a 75 *kW*. Essa modalidade pode ser instalada em unidades consumidoras dos grupos A ou B, sendo voltada principalmente para atender consumidores residenciais e comerciais de pequeno e médio porte.

Por outro lado, a minigeração distribuída refere-se a uma central geradora de energia elétrica renovável ou de cogeração qualificada, com potência instalada, em corrente alternada, maior que 75 *kW* e menor ou igual a:

- 5 *MW* para centrais geradoras de fontes despacháveis;
- 3 *MW* para as demais fontes não enquadradas como despacháveis;
- 5 *MW* para unidades consumidoras conectadas até 7 de janeiro de 2022 ou que protocolaram solicitação de orçamento de conexão até 7 de janeiro de 2023, independentemente do enquadramento como despacháveis.

As fontes despacháveis são aquelas cuja geração pode ser controlada, como as termelétricas e hidrelétricas. Em contraste, as fontes não despacháveis, como solar e eólica, dependem de recursos naturais e apresentam intermitência.

A cogeração qualificada, por sua vez, refere-se a sistemas que produzem, de forma combinada, energia elétrica e térmica a partir de uma única fonte de combustível, alcançando alta eficiência energética.

Para simplificar, as características principais de cada modalidade estão resumidas na Tab. 2.

Tabela 2 – Características de *UFVs*: Microgeração e Minigeração Distribuída.

<b>Categoria</b>	<b>Microgeração</b>	<b>Minigeração</b>
Potência Instalada	$\leq 75 \text{ kW}$	$75 \text{ kW} < \text{Potência} \leq 5 \text{ MW}$
Grupo de Consumo	Grupo A ou B	Grupo A

Fonte: Elaborado pelo autor.

### 3.1.1 Aplicação das Usinas Fotovoltaicas

A energia solar fotovoltaica pode ser aplicada em diferentes configurações, adaptando-se às necessidades específicas de geração e consumo de energia. As *UFV*, segundo (GINU *et al.*, 2024), são classificadas em três tipos: Sistemas Isolados (*Off – grid*), Sistemas Conectados à Rede (*On – grid*) e Sistemas Híbridos.

Em primeiro momento, os sistemas *Off – grid* são caracterizados por sua operação independente da rede elétrica convencional. Essa modalidade é amplamente empregada em áreas remotas, onde o acesso à rede elétrica é inexistente ou inviável economicamente. Para garantir o fornecimento de energia durante a noite ou em períodos de baixa geração, esses sistemas dependem, geralmente, de baterias como principal meio de armazenamento de energia.

No entanto, o alto custo das baterias, em alguns casos, inviabiliza sua aplicação em larga escala. Paralelamente, outras tecnologias de armazenamento energético têm sido desenvolvidas, como o uso de supercapacitores, que oferecem alta eficiência em descargas rápidas, e sistemas baseados em armazenamento de hidrogênio, que possibilitam o armazenamento a longo prazo. Apesar de promissoras, essas soluções ainda enfrentam desafios relacionados ao custo e à viabilidade tecnológica, sendo objeto de estudos contínuos para aprimorar sua aplicação prática.

Em segundo momento, os sistemas *On – grid* são os mais comuns em ambientes residenciais, urbanos e industriais. Eles operam conectados à rede elétrica, permitindo que a energia excedente gerada pelos módulos fotovoltaicos seja injetada na rede, gerando créditos. Essa configuração é regulamentada no Brasil por meio de normas como a Resolução Normativa nº 14.300/2022 da (ANEEL, 2025), que define os critérios para compensação de energia no modelo de geração distribuída.

Por fim, os sistemas híbridos combinam as características dos sistemas isolados e conectados à rede. Além de se conectarem à rede elétrica, esses sistemas utilizam baterias para armazenamento de energia, proporcionando maior flexibilidade e resiliência. Eles são indicados para aplicações em que a continuidade do fornecimento de energia é crítica,

como hospitais, indústrias e centros de dados, bem como para situações onde deseja-se realizar controle pelo lado da demanda.

Cada uma dessas configurações apresenta vantagens específicas, permitindo que as usinas fotovoltaicas sejam implementadas em diversos cenários, desde residências e pequenos negócios até grandes empreendimentos industriais e áreas remotas. Essa flexibilidade contribui significativamente para a expansão e popularização da energia solar fotovoltaica como uma solução sustentável e eficiente.

Contudo, embora os sistemas fotovoltaicos apontem como uma das principais fontes de geração de energia limpa no Brasil, diversas instalações têm apresentado problemas ao qual precisam de metodologias, análise e classificação para uma melhor eficiência.

### 3.1.2 Problemas em Usinas Fotovoltaica

O crescimento exponencial da instalação de usinas de Micro e Minigeração Distribuída (*MMGD*), nos últimos anos, demonstra o grande desenvolvimento no setor e valida a importância de manter essas instalações eficientes. Entretanto, muitos projetos e a montagem das usinas apresentam erros que impactam de forma direta no rendimento, segurança e retorno financeiro do empreendimento.

Segundo (PIMENTEL *et al.*, 2022), os problemas em sistemas fotovoltaicos podem ser classificados da seguinte forma: estruturais, elétricos e de desempenho.

Os problemas estruturais, estão associados as estruturas que suportam os painéis fotovoltaicos, seja no solo ou em telhados. Dentre os problemas, destaca-se o dimensionamento inadequado das estruturas, componentes e estruturas improvisados e, por fim, correção inadequada da inclinação dos módulos (PIMENTEL *et al.*, 2022).

Os problemas elétricos, por sua vez, podem ocorrer por diversos fatores, desde de erro de fabricação, como falhas na instalação e fatores externos. Dentre os problemas, estão: a falha de equipotencialização, dimensionamento incorreto da distribuição dos cabos por eletrodutos, clipagem incorreta dos conectores *MC4* e terminais, aperto excessivo ou insuficiente nos bordos de conexão, improvisos nas montagem, emendas inadequadas, dentre outros (PIMENTEL *et al.*, 2022).

Por fim, os problemas de desempenho são comuns em instalações fotovoltaicas. Dentre os problemas, podemos citar o azimuth ou inclinação inadequados, configuração inadequadas dos arranjos por String, avaliação inadequada de sombreamento, sujeidade nos módulos, microfissuras e fatores externos (PIMENTEL *et al.*, 2022).

3.1.3 Técnicas de Comissionamento

O comissionamento garante a confiabilidade, segurança e otimização das instalações. Esse processo deve ser realizado por profissionais habilitados para executar os procedimentos que a NBR 16274:2014 indica, seguindo os seguintes requisitos de comissionamento em UFV: inspeção, ensaio de categoria 1, ensaio de categoria 2 e ensaios adicionais. São realizados testes, medições, inspeção e ensaios a fim de identificar possíveis erros que comprometam a plena operação e geração das usinas (GOKGOZ *et al.*, 2024; SANTOS *et al.*, 2022).

A inspeção tem o objetivo de realizar um exame na instalação precedente o comissionamento, a fim de avaliar a instalação, montagem dos equipamentos, utilização dos equipamentos de acordo com os requisitos da NBR (NBR-16690, 2019). Segundo a (NBR-16274, 2014), na inspeção, deve-se verificar os itens conforme apresentado no Quadro 1.

Quadro 1: Inspeções e verificações para sistemas fotovoltaicos.

Item	Inspeção	Verificação
1	Sistema de corrente contínua (CC)	Proteção, aterramento e conexão dos cabos CC.
2	Sistema de corrente alternada (CA)	Seccionamento e conformidade dos parâmetros do inversor com as normas vigentes.
3	Proteção contra choques elétricos e sobretensão	Dispositivos de proteção e aterramento do sistema fotovoltaico.
4	Etiquetagem e identificação	A correta identificação e etiquetagem dos equipamentos das UFV.
5	Instalação mecânica	Ventilação por trás dos arranjos, armação e equipamentos UFV são à prova de intempéries.

Fonte: Elaborado pelo autor.

Os ensaios de categoria 1, buscam realizar uma sequência mínima que deve ser aplicada em todos sistemas fotovoltaicos independente da potência instalada. Com isso, o Quadro 2 detalha os ensaios que devem ser aplicados conforme a (NBR-16274, 2014).

Enquanto os ensaios da categoria 2, destinam-se a usinas e sistemas maiores. Portanto, antes de iniciar os ensaios dessa categoria, deve-se verificar que todos da categoria 1 foram realizados com êxito. Segundo a (NBR-16274, 2014), os ensaios da categoria 2 estão ilustrados no Quadro 3.

Quadro 2: Ensaios e objetivos para inspeção de sistemas fotovoltaicos.

Item	Ensaio	Objetivos
1	Circuito de corrente alternada (CA)	Testar a continuidade e equipotencialização dos condutores no lado CC, utilizando o Miliohmímetro ou Microhmímetro.
2	Continuidade e equipotencialização	Testar a continuidade e equipotencialização dos condutores no lado CC, utilizando o Miliohmímetro ou Microhmímetro.
3	Polaridade	Verificar, utilizando um alicate amperímetro, a polaridade em todos condutores CC, a fim de identificar inversão dos polos positivo e negativo.
4	Caixa de junção	Verificar, basicamente, se ocorreu inversão na ligação das Strings Box utilizando alicate amperímetro.
5	Corrente (curto circuito ou operacional) e Tensão (circuito aberto)	Consiste na verificação de falhas graves na fiação do sistema. É preferível realizar o ensaio de curto circuito, devido não haver interferência do inversor.
6	Funcionalidade do(s) sistema(s)	Verificar os dispositivos de seccionamento e funcionalidade dos inversores conforme indicado pelo fabricante.
7	Resistência de isolamento	Identificar possíveis defeitos referente à resistência de isolamento e/ou defeitos de fabricação. Nesse processo utiliza-se um Megôhmímetro ou equipamento especializado.

Fonte: Elaborado pelo autor.

Quadro 3: Ensaios de categoria 2.

Item	Ensaio	Objetivos
1	Curva Corrente x Tensão (I-V)	Fornece informações a respeito dos arranjos fotovoltaicos das UFV e possíveis defeitos. A realização desse processo é utilizando o traçador de curva IV.
2	Inspeção com câmera infravermelha (IR)	Visa identificar pontos quentes nas células fotovoltaicas. É utilizando, normalmente, câmera infravermelha (IR).

Fonte: Elaborado pelo autor.

Por fim, os ensaios adicionais podem ocorrer mediante solicitação dos clientes ou indicação do profissional, visto que os ensaios da categoria 1 e 2 não foram capazes de identificar o problema na determinada usina. Todo procedimento descrito, é de suma

importância para operação e eficiência do sistema. Os ensaios adicionais estão ilustrado no Quadro 4.

Quadro 4: Ensaio adicionais.

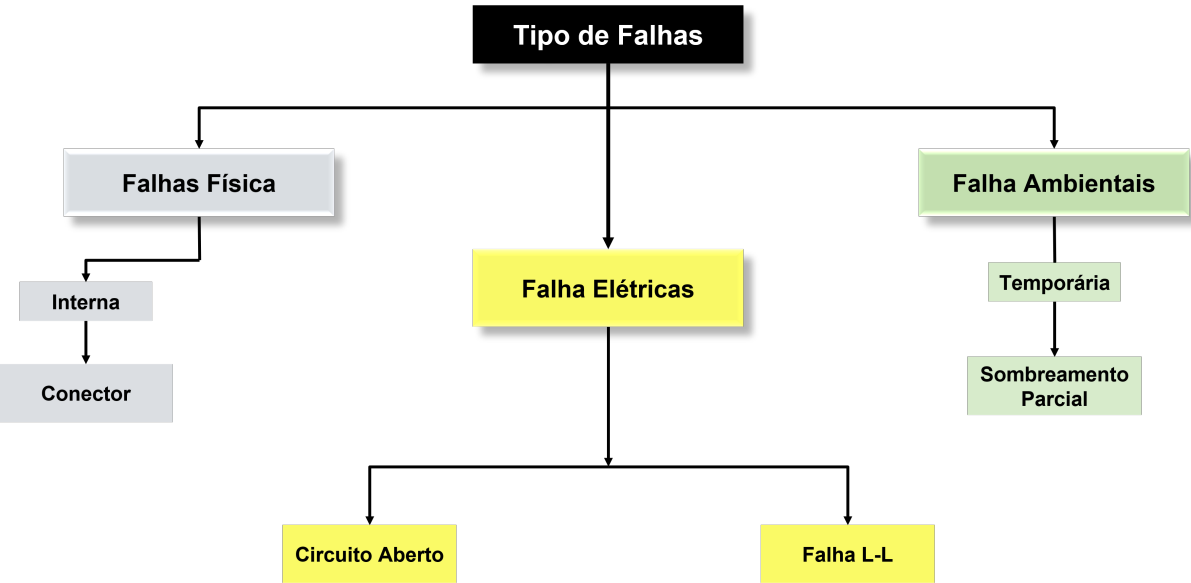
Item	Ensaio	Objetivos
1	Tensão ao solo – sistema com aterramento resistivo	Utilizado para verificar, no lado CC, se as tensões em relação ao solo e/ou correntes de fuga estão na faixa de limites aceitáveis.
2	Diodo de bloqueio	Visa verificar a conexão correta do diodo e evidência de superaquecimento e carbonização.
3	Resistência de isolamento úmido	Avalia a resistência de isolamento elétrico do arranjo fotovoltaico sob condições operacionais úmidas.
4	Avaliação de sombreamento	Visa verificar possíveis problemas que culminam na perda de eficiência da UFV.

Fonte: Elaborado pelo autor.

3.2 Falhas em Usinas Fotovoltaicas

Conforme descrito por (GOKGOZ *et al.*, 2024), as falhas em UFV estão entre as principais responsáveis pela baixa eficiência dos sistemas fotovoltaicos. Este trabalho apresentará um diferencial por abordar diferentes tipos de falhas, incluindo de natureza elétrica,física e ambiental. Além de discutir o impacto desses problemas nos aspectos técnico e econômico. A Fig. 3 ilustra os tipos de falhas abordados no presente trabalho.

Figura 3 – Falhas no Lado de Corrente Contínua.



Fonte: Elaborado pelo autor.

### 3.2.1 Falha de Circuito Aberto

A falha de circuito aberto ocorre devido à interrupção de continuidade da corrente em um determinado caminho (TAREK *et al.*, 2021). As causas mais comuns incluem corrosão nos conectores, conexões de cabos frouxas e erros humanos durante a montagem do sistema. A Fig. 4 apresenta uma representação básica dessa falha.

### 3.2.2 Falha Curto Circuito Linha-Linha

De acordo com (GOKGOZ *et al.*, 2024), os curtos circuitos ocorrem quando há uma conexão direta entre dois pontos com diferença de potencial, formando um caminho de baixa impedância e resultando em uma elevada circulação de corrente.

No caso de curto circuito Linha-Linha, a falha decorre da conexão inadequada entre condutores, o que cria um caminho de baixa impedância ideal para a passagem de corrente (ALI *et al.*, 2022). A Fig. 4 ilustra o curto circuito Linha-Linha no lado de corrente contínua das *UFV*.

### 3.2.3 Falha de Sombreamento

O sombreamento em sistemas fotovoltaicos pode ser classificado em duas categorias: parcial e permanente. Embora não seja considerado uma falha propriamente dita, o sombreamento pode reduzir significativamente a geração de energia e, em casos permanentes, causar pontos quentes (*Hot Spots*), comprometendo a vida útil dos módulos (TAREK *et al.*, 2021).

O sombreamento parcial ocorre, por exemplo, devido à passagem de nuvens que bloqueiam temporariamente a irradiância direta nos módulos. Já o sombreamento permanente é causado por obstáculos fixos, como árvores ou edifícios próximos às instalações, que projetam sombras constantes sobre os módulos. A Fig. 4 apresenta uma representação de sombreamento causado por nuvens (ZHANG, 2020).

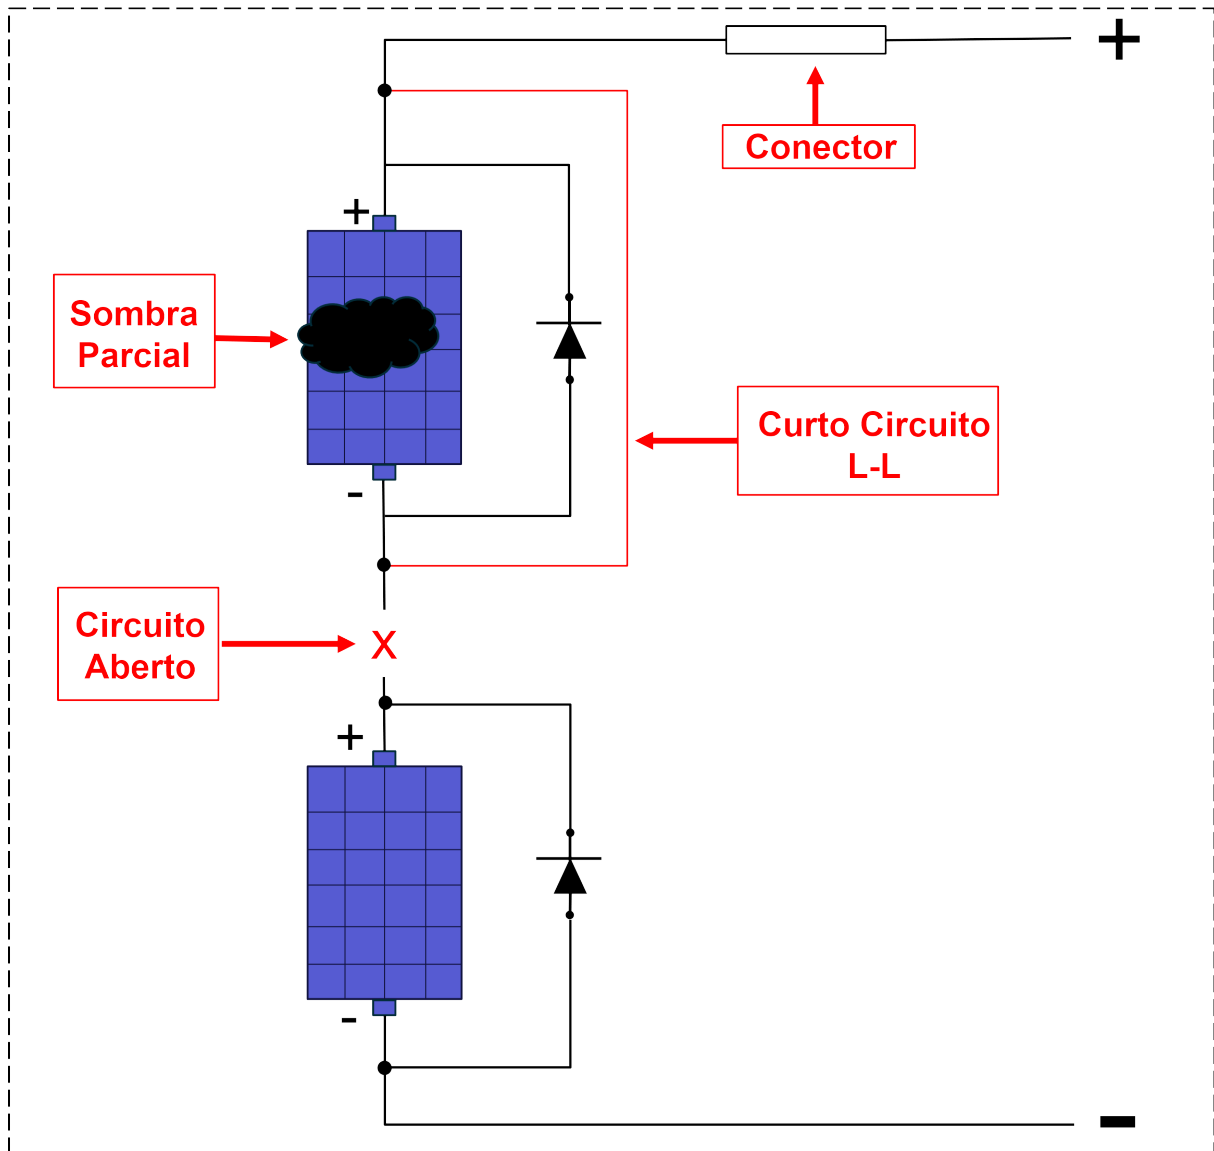
### 3.2.4 Falha nos Conectores

As falhas nos conectores das *UFV* são um dos fatores que contribuem para a redução da eficiência em sistemas fotovoltaicos. No presente trabalho, essa falha foi simulada conforme descrito por (HOJABRI *et al.*, 2022), conectando-se um resistor em série entre as ligações dos módulos.

Além de reduzir a eficiência do sistema, essa falha pode acarretar problemas graves, como a formação de arcos fotovoltaicos, que representam um risco significativo devido à possibilidade de incêndios (HOJABRI *et al.*, 2022). A Fig. 4 ilustra a configuração utilizada para simular essa falha.



Figura 4 – Configuração de Falhas.



Fonte: Elaborado pelo autor.

### 3.2.5 Impacto das Falhas em Usinas Fotovoltaicas

Os problemas das falhas em sistemas fotovoltaicos não são apenas técnicos, mas também econômicos. Em primeiro lugar, essas falhas afetam diretamente a eficiência dos sistemas, diminuindo a potência de saída do inversor. Essa redução na geração de energia está diretamente associada às perdas financeiras do projeto, comprometendo o retorno do investimento.

Em segundo lugar, as falhas em *UFVs* elevam os custos *O&M* devido à necessidade de reparos frequentes e mão de obra qualificada. Normalmente, grandes usinas são instaladas em locais remotos, exigindo o deslocamento de profissionais para corrigir os problemas. Além disso, há perdas indiretas, como o tempo de inatividade da usina e a consequente perda de receita durante os períodos de reparo.

Outro impacto significativo das falhas nos sistemas fotovoltaicos é o comprometimento da confiabilidade geral do sistema. Falhas recorrentes podem gerar interrupções frequentes na geração de energia, afetando a estabilidade do fornecimento à rede elétrica ou aos consumidores finais. A confiabilidade de uma usina fotovoltaica é um fator estratégico, especialmente em projetos de grande escala que atendem a demandas críticas de energia. Além disso, essas interrupções podem reduzir a confiança dos investidores e parceiros no desempenho do sistema, colocando em risco a viabilidade de futuros investimentos.

As falhas também influenciam negativamente a vida útil dos componentes do sistema fotovoltaico. Condições de curto circuito, sombreamento, circuito aberto submetem os componentes a estresses adicionais, acelerando o processo de degradação. Esse desgaste prematuro afeta cabos, conectores, módulos e inversores. Com o tempo, esses efeitos reduzem a expectativa de vida útil do sistema, aumentando os custos totais do projeto devido à substituição antecipada de componentes.

Além do impacto técnico e econômico, as falhas em sistemas fotovoltaicos geram desafios operacionais que complicam a gestão de manutenção. Um sistema com baixa confiabilidade exige monitoramento constante e uma resposta ágil para corrigir problemas à medida que surgem. Isso acarreta custos adicionais com sistemas de monitoramento remoto e requer equipes de manutenção altamente capacitadas. Em usinas de grande porte, essas exigências tornam-se ainda mais complexas, pois cada componente precisa ser inspecionado regularmente para garantir a operação ideal.

Por fim, é importante destacar que a redução da eficiência energética causada por falhas não se restringe apenas ao impacto imediato na geração de energia. Além disso, falhas não corrigidas comprometem os indicadores de desempenho do projeto, como o índice de desempenho (PR, Performance Ratio), ficando evidente a importância do comissionamento, padronização e classificação das falhas em *UFV*.

### 3.3 Classificação das Falhas

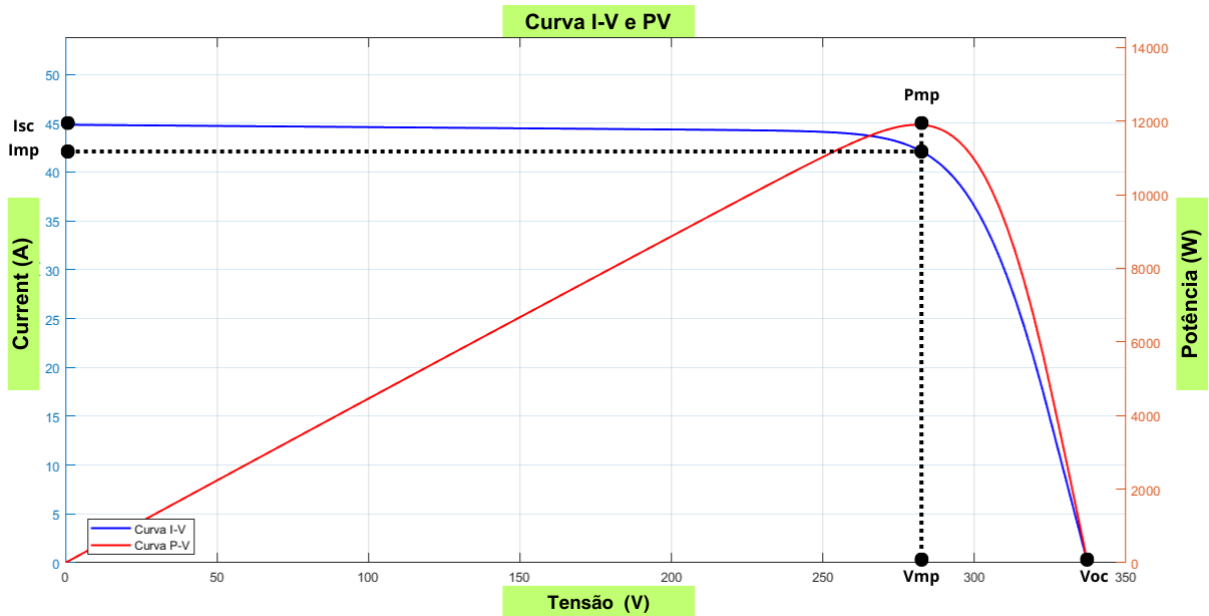
Nessa seção, será apresentada a classificação das falhas. Inicialmente, será demonstrada a metodologia de criação do banco de dados, com a extração das principais características das curvas  $I - V$  e  $P - V$ . Em seguida, será descrito o tratamento dos dados, incluindo o processo de normalização. Além disso, será detalhada a técnica de classificação utilizada, com ênfase nas abordagens One Versus One (*OVO*) e One Versus Rest (*OVR*), destacando suas principais características. Por fim, serão apresentadas as métricas de validação aplicadas à classificação multiclasse.

### 3.3.1 Criação do Banco de Dados

Para criação do banco de dados, utilizou-se um algoritmo, no Matlab, para extrair as características principais das curvas  $I - V$  e  $P - V$  de forma automática.

As características extraídas, conforme descrito na Fig. 5, são: corrente de curto-circuito ( $I_{sc}$ ), tensão de circuito aberto ( $V_{oc}$ ), corrente de máxima potência ( $I_{mp}$ ), tensão de máxima potência ( $V_{mp}$ ) e potência máxima ( $P_{mp}$ ).

Figura 5 – Dados Extraídos da Curva I-V e P-V



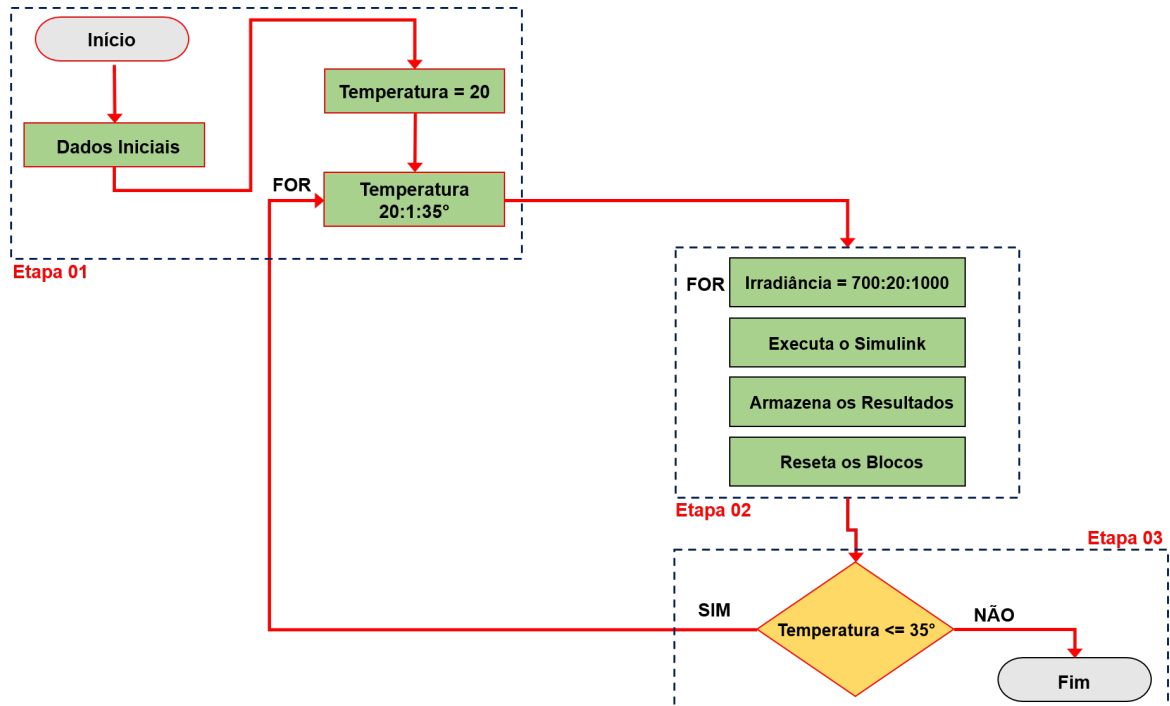
Fonte: Elaborado pelo autor.

Para essa extração, foi desenvolvido um algoritmo, utilizando a linguagem  $C$  do Matlab, conforme ilustrado no fluxograma simplificado da Fig. 6.

Na etapa 01, realizam-se as definições iniciais dos dados de temperatura e a estrutura para armazenamento das características. Em seguida, um laço de repetição  $FOR$  é criado, iniciando com a temperatura de  $20^{\circ}\text{C}$  e variando em incrementos de  $1^{\circ}$  até atingir  $35^{\circ}\text{C}$ .

Na etapa 02, o algoritmo entra em um loop no qual, mantendo a temperatura fixa, itera sobre os valores de irradiância de  $700 \text{ W/m}^2$  a  $1.000 \text{ W/m}^2$ , faixa recomendada pela (NBR-16274, 2014), para o levantamento em campo das curvas  $I - V$  e  $P - V$ , com incrementos de  $20 \text{ W/m}^2$ . Essa varredura é utilizada para gerar o banco de dados, composto por 3.712 amostras na configuração com uma string e 4.640 amostras na configuração com três strings.

Figura 6 – Fluxograma do Algoritmo do Método Utilizado para Obtenção dos Dados da Curva I-V.



Fonte: Elaborado pelo autor.

Ainda na etapa 02, é realizada a simulação do modelo com o Simulink e extração das características das curvas para todos valores de irradiância e temperatura nas faixas descritas pelo os *FOR*. Além disso, todos os valores são armazenados em um arquivo com extensão .csv que pode ser aberto no Excel.

Por fim, na Etapa 03, verifica-se se ainda existe algum valor de temperatura menor ou igual a 35°C cujas características não foram extraídas e armazenadas. Caso todos os valores tenham sido processados, o procedimento é encerrado.

A Tabela 3 apresenta um exemplo da estrutura dos dados criados, considerando a variação de irradiância com incrementos de 20 W/m<sup>2</sup> e temperatura de 20°C.

Todo o processo de extração de características para a construção dos dados foi realizado em um notebook Acer Aspire 5, equipado com um processador Intel Core i5 de 10ª geração. O código foi implementado no Matlab, conforme ilustrado no fluxograma da Figura 6, em conjunto com o Simulink, que emula os modelos propostos.

A Tabela 4 apresenta os tempos necessários para a construção do banco de dados, considerando as simulações com falhas e os subconjuntos de dados de 1984 e 2480 amostras, correspondentes às configurações com 1 e 3 strings, respectivamente.

Tabela 3 – Exemplo do banco de dados com diferentes irradiância e temperatura de 20°C.

Temp. (20°C)	Irradiância (W/m <sup>2</sup> )	Voc (V)	Isc (A)	Pmax (W)	Imax (A)	Vmax (V)
20.00	1000.00	337.25	14.95	3966.57	14.11	281.15
20.00	980.00	336.92	14.65	3889.38	13.87	280.49
20.00	960.00	336.59	14.35	3812.00	13.57	280.82
20.00	940.00	335.92	14.05	3734.40	13.28	281.15
20.00	920.00	335.59	13.75	3656.63	12.99	281.49

Fonte: Autoria Própria.

Tabela 4 – Tempo total para construção do banco de dados considerando os tipos de falha e a quantidade de amostras por configuração.

Tipo	1 String (1.984 amostras)	3 Strings (2.480 amostras)
Condição normal	00:19:30	01:47:30
Sombreamento	00:19:45	01:57:05
Curto-circuito	00:19:54	01:55:50
Falha no conector	00:19:48	01:53:12
Circuito Aberto		01:52:34
<b>Tempo total</b>	<b>01:18:57</b>	<b>09:26:11</b>

Fonte: Autoria Própria.

### 3.3.2 Tratamento de Dados

Inicialmente, os dados foram organizados em três bancos distintos, considerando variações nas condições de irradiância e temperatura, bem como diferentes quantidades de amostras para os sistemas com 1 e 3 strings.

O primeiro banco de dados contém 704 amostras para o sistema com 1 string e 880 amostras para o sistema com 3 strings, com temperatura variando de 20°C a 35°C e irradiância de 700 W/m<sup>2</sup> a 1000 W/m<sup>2</sup>, com incrementos de 30 W/m<sup>2</sup>.

O segundo banco de dados possui 1024 amostras para 1 string e 1280 amostras

para 3 strings, considerando a mesma faixa de temperatura 20°C a 35°C e irradiância 700 W/m<sup>2</sup> a 1000 W/m<sup>2</sup>, porém com incrementos de 20 W/m<sup>2</sup>.

Já o terceiro banco de dados é o mais amplo, com 1984 amostras para o sistema de 1 string e 2480 amostras para o de 3 strings, também variando temperatura de 20°C a 35°C e irradiância de 700 W/m<sup>2</sup> a 1000 W/m<sup>2</sup>, com incrementos de 10 W/m<sup>2</sup>.

Em todos os casos, os dados foram distribuídos aleatoriamente, sendo 70% utilizados para treinamento e 30% para teste, separadamente para cada configuração.

Na etapa subsequente, as falhas foram rotuladas de acordo com o circuito simulado. Para o circuito de 1 String, os rótulos atribuídos foram: 0 para condição normal, 1 para sombreamento, 2 para curto-circuito e 3 para falha no conector. No circuito de 3 String, foi incluído o rótulo 4 para circuito aberto.

Essa rotulagem é crucial para a identificação precisa das condições operacionais do sistema. Nesse processo é possível realizar o treinamento e teste, apresentando o conjuntos de dados que pertence a cada classe.

Após a separação dos dados e atribuição de rótulos, realizou-se a normalização das variáveis para garantir uma escala uniforme entre elas. O processo de normalização aplicado foi o `MinMaxScaler`, que transforma os dados para que seus valores estejam entre 0 e 1, de acordo com a seguinte fórmula:

$$x_{\text{normalized}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.1)$$

onde  $x$  é o valor original,  $x_{\min}$  e  $x_{\max}$  são os valores mínimo e máximo do conjunto de dados, respectivamente.

Essa etapa é fundamental para melhorar o desempenho dos algoritmos de classificação, garantindo que variáveis com amplitudes diferentes não influenciem desproporcionalmente o modelo.

### 3.3.3 Classificação Multiclasse

Problemas de classificação geralmente verificam se um determinado dado pertence ou não a uma classe específica. Algoritmos que não trabalham com multiclasse podem apresentar bom desempenho em cenários binários. No entanto, muitos problemas envolvem mais de duas classes, tornando necessário o uso de métodos de multi classificação.

Métodos heurísticos de classificação, como One Versus Rest (*OVR*) e One Versus One (*OVO*), são comumente utilizados para lidar com essa complexidade. Essas abordagens foram inicialmente aplicadas com *SVM* por (WESTON; WATKINS, 1999) e discutidas em maior profundidade por (HASTIE *et al.*, 2009).

### 3.3.3.1 One versus Rest (OVR)

A técnica *OVR* transforma um problema de multi classificação em vários problemas binários. Cada classe é treinada contra todas as outras combinadas.

Nesse método, um classificador binário é treinado para cada classe  $C_i$ , tratando os exemplos dessa classe como positivos (+1) e todos os demais exemplos como negativos (-1):

$$f_i(x) = \begin{cases} +1, & \text{se } x \text{ pertence à classe } C_i, \\ -1, & \text{caso contrário.} \end{cases}$$

Dado um problema, por exemplo, com 3 classes ( $C_1$ ,  $C_2$  e  $C_3$ ). Usando o método *OVR*, treinamos um classificador binário para cada classe.

#### Classificadores Treinados:

- $score_1(x)$ : Distingue  $C_1$  (positivo) de  $C_2$  e  $C_3$  (negativos).
- $score_2(x)$ : Distingue  $C_2$  (positivo) de  $C_1$  e  $C_3$  (negativos).
- $score_3(x)$ : Distingue  $C_3$  (positivo) de  $C_1$  e  $C_2$  (negativos).

Cada classificador calcula uma pontuação:

$$score_k(x) = \sum_{m=1}^M \eta \cdot h_{k,m}(x)$$

Onde:

- $M$ : número de árvores,
- $\eta$ : taxa de aprendizado,
- $h_{k,m}(x)$ : saída da árvore  $m$ -ésima para a classe  $k$ .

**Pontuação para Predição:** Cada classificador retorna uma pontuação indicando a confiança na predição:

- $score_1(x)$
- $score_2(x)$
- $score_3(x)$

A partir das pontuações obtidas, calcula-se a probabilidade da saída  $x$  pertencer a determinada classe  $k$ , por meio da seguinte equação:

$$P_k(x) = \frac{1}{1 + e^{-score_k(x)}} \quad (3.2)$$

A equação  $P_k(x)$  é utilizada para transformar o  $score_k(x)$  em probabilidade para cada classe  $k$ .

A classe final prevista é aquela associada à maior probabilidade, determinada pela seguinte equação:

$$\hat{y} = \arg \max_k P_k(x) \quad (3.3)$$

Neste trabalho, o algoritmo *XGBClassifier*, desenvolvido por (CHEN; GUESTRIN, 2016), baseado em gradient boosting, é empregado como classificador base para cada subproblema binário gerado pelo *OVR*, devido à sua eficácia.

### 3.3.3.2 One versus One (OVO)

Diferentemente do *OVR*, a técnica *OVO* cria um classificador para cada par de classes, comparando-as diretamente.

No método *OVO*, cada par de classes  $C_i$  e  $C_j$  ( $i \neq j$ ) é considerado individualmente, resultando em  $\binom{K}{2} = \frac{K(K-1)}{2}$  classificadores binários, onde  $K$  é o número total de classes.

Dado o mesmo exemplo da subseção 3.3.3.1 de classificação com 3 classes:  $C_1$ ,  $C_2$  e  $C_3$ . Usando o método *OVO*, treinamos um classificador binário para cada par de classes.

#### Classificadores Treinados:

- $score_{12}(x)$ : Distingue  $C_1$  de  $C_2$ .
- $score_{13}(x)$ : Distingue  $C_1$  de  $C_3$ .
- $score_{23}(x)$ : Distingue  $C_2$  de  $C_3$ .

Assim como na técnica *OVR*, cada classificador é treinado utilizando o método *XGBClassifier*, que utiliza múltiplas árvores de decisão para obter o  $score_{ij}(x)$  previsto. O  $score$  é determinado pela seguinte fórmula:

$$score_{ij}(x) = \sum_{m=1}^M \eta \cdot h_{ij,m}(x)$$

Onde:



- $M$  é o número total de árvores de decisão;
- $\eta$  é a taxa de aprendizado;
- $h_{ij,m}(x)$  é a saída da  $m$ -ésima árvore no classificador.

A pontuação é transformada em probabilidade usando a função sigmoide:

$$P_{ij}(x) = \frac{1}{1 + e^{-score_{ij}(x)}}$$

A predição da classe é feita da seguinte forma:

$$\hat{y}_{ij} = \begin{cases} C_i, & \text{if } P_{ij}(x) > 0.5 \\ C_j, & \text{caso contrário} \end{cases}$$

#### Votação Majoritária:

Cada classificador vota em uma classe. O número de votos recebidos pela classe  $C_k$  é dado por:

$$Votes_k(x) = \sum_{i=1}^K \sum_{j=i+1}^K 1[\hat{y}_{ij} = C_k]$$

A classe final prevista é aquela que recebe o maior número de votos:

$$\hat{y}(x) = \arg \max_k Votes_k(x)$$

A Tabela 5 apresenta a comparação entre os dois métodos. Em geral, a técnica *OVR* têm melhor desempenho comparada a *OVO* quando se tem grande volumes de dados.

## 3.4 Métricas de Avaliação

Nesta seção, será descrito as principais métricas de avaliação utilizadas neste trabalho: acurácia, precisão, sensibilidade e matriz de confusão.

### 3.4.1 Acurácia

A acurácia, de forma direta, mede a proporção de previsões corretas em relação ao total de previsões feitas.

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (3.4)$$

Tabela 5 – Comparação entre o One Versus One (OVO) e One Versus Rest (OVR).

Característica	One Versus One (OVO)	One Versus Rest (OVR)
Número de Classificadores	$\frac{K(K-1)}{2}$	$K$
Complexidade	Mais alta	Mais baixa
Classificação	Cada par de classes é tratado separadamente	Cada classe é comparada contra todas as outras

Fonte: Elaborado pelo autor

Onde:

- **TP** (True Positives): Verdadeiros positivos.
- **TN** (True Negatives): Verdadeiros negativos.
- **FP** (False Positives): Falsos positivos.
- **FN** (False Negatives): Falsos negativos.

### 3.4.2 Precisão

A precisão mede a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo.

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3.5)$$

### 3.4.3 Sensibilidade

O recall, ou sensibilidade, mede a proporção de verdadeiros positivos identificados em relação ao total de elementos que realmente são positivos.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3.6)$$

### 3.4.4 Matriz de Confusão

A matriz de confusão, apresentado na Tab. 6, descreve o desempenho do modelo, mostrando a contagem de previsões verdadeiras e falsas para cada classe.

Tabela 6 – Exemplo de Matriz de Confusão.

	Previsão Positiva	Previsão Negativa
Positivo Real	TP	FN
Negativo Real	FP	TN

Essas métricas fornecem uma visão abrangente sobre o desempenho do modelo de classificação, sendo essenciais para avaliar sua eficácia, especialmente em cenários com classes desbalanceadas.

## 4 Método Proposto

Esta seção apresenta a metodologia desenvolvida para o trabalho. Inicialmente, são descritos e explicados o modelo do sistema fotovoltaico utilizado na simulação implementado no Matlab/Simulink. Em seguida, detalham-se os parâmetros e a configuração dos equipamentos simulados, com o objetivo de permitir a reprodução do modelo e compreender o processo de simulação sob condições normais e com falhas. Por fim, são abordados os procedimentos de inserção de falhas e a modelagem utilizada por meio do software de simulação.

### 4.1 Modelo dos Sistemas Simulados

Os modelos utilizados para o levantamento das curvas foram idealizados com duas configurações distintas, ambas aplicadas durante o processo de comissionamento de sistemas fotovoltaicos. A primeira configuração, com 1 string composta por sete módulos em série, permite uma análise mais detalhada do sistema, favorecendo a identificação de falhas específicas.

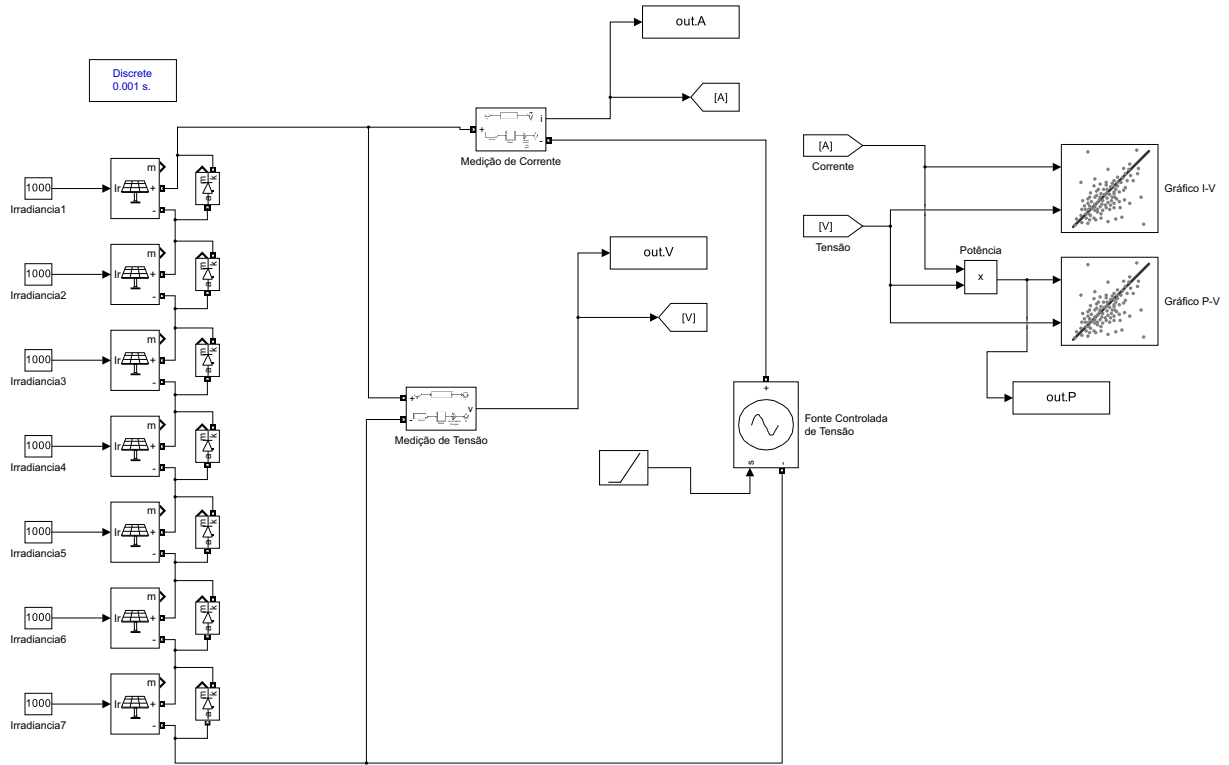
Já a segunda configuração, com 3 strings em paralelo também com sete módulos em série em cada string proporciona uma visão mais ampla do comportamento do sistema como um todo. A combinação dessas duas abordagens permite uma avaliação mais completa e eficaz do sistema fotovoltaico, além de conferir maior robustez ao método proposto.

#### 4.1.1 Modelo 1 String

O modelo descrito na Fig. 7 representa a configuração de uma String de módulos fotovoltaicos. Essa abordagem é amplamente utilizada no campo para o levantamento de curvas  $I-V$  e  $P-V$ , pois proporciona uma visão mais detalhada do comportamento de um conjunto específico de módulos conectados em série. Nesse modelo, foram implementadas falhas simuladas de sombreamento, curto-circuito e defeitos nos conectores, possibilitando a análise de diferentes cenários de operação e a identificação de potenciais problemas no sistema (SANTOS *et al.*, 2022).

Essa configuração com 1 String é geralmente utilizada como padrão para testes devido à sua simplicidade e facilidade de controle. No entanto, com o objetivo de expandir as análises e aproximar os modelos das condições reais de operação em campo, foi desenvolvido um segundo modelo que utiliza 3 Strings.

Figura 7 – Esquema do Modelo com 1 String.



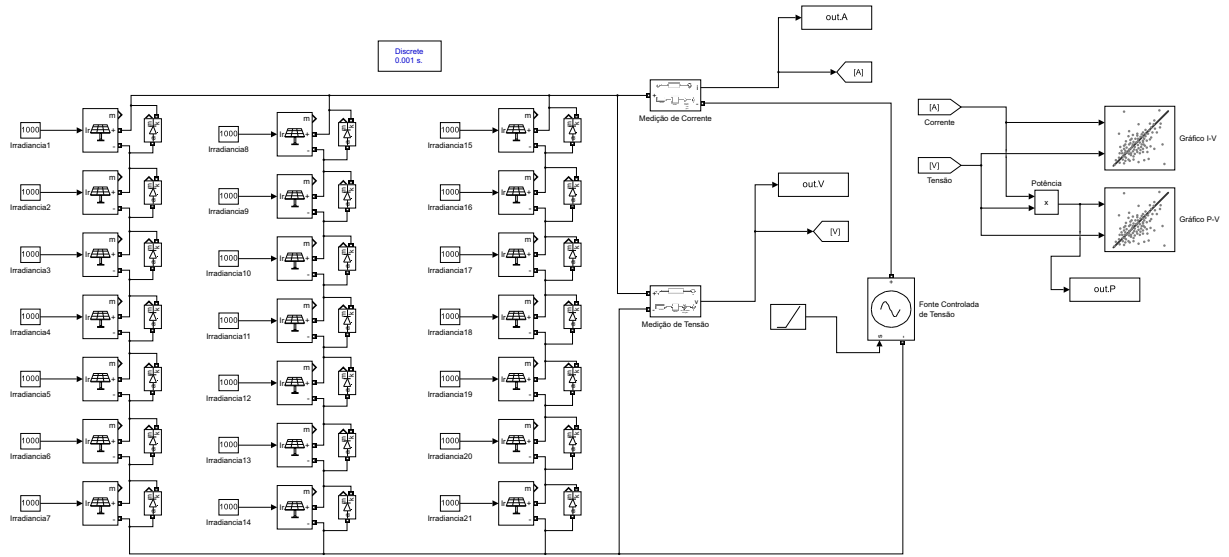
Fonte: Elaborado pelo autor.

#### 4.1.2 Modelo 3 String

O modelo com 3 Strings, conforme descrito na Fig. 8, foi implementado para representar sistemas fotovoltaicos maiores e mais complexos. Nessa configuração, cada String é composta por 7 módulos conectados em série, e as Strings estão conectadas em paralelo. Essa abordagem é essencial para simular cenários mais próximos das condições reais de operação, uma vez que sistemas fotovoltaicos de grande porte frequentemente utilizam essa disposição (SANTOS *et al.*, 2022).

Ao utilizar 3 Strings, foi possível avaliar o impacto de falhas de forma geral e como essas falhas afetam o desempenho geral do sistema fotovoltaico. Nessa etapa foram implementadas todos modos de falhas descritos na subseção 4.1.1, com uma String, com o acréscimo da condição de circuito aberto.

Figura 8 – Esquema do Modelo com 3 String.



Fonte: Elaborado pelo autor.

## 4.2 Descrição e Parâmetros

Os componentes do diagrama de blocos implementado no Matlab/Simulink e suas características principais são descritos a seguir.

Inicialmente, foi utilizado o bloco denominado "Constant", no Simulink, para representar o valor de irradiância do sistema, que varia de 700 a 1000 W/m<sup>2</sup>. Este bloco permite simular diferentes condições de irradiância, reproduzindo diferentes cenários de operação em sistemas fotovoltaicos.

Além disso, foi empregado o módulo "PV Array", que representa o módulo fotovoltaico. Nesse modelo, é possível ajustar seus parâmetros e simular o comportamento de módulos reais. Os dados utilizados para configurar o módulo fotovoltaico simulado, baseados em um modelo real, estão apresentados na Tabela 7.

Tabela 7 – Parâmetros do Módulo Fotovoltaico

Parâmetro	Valor
Strings em Paralelo	1
Módulos em Série por String	1
Potência Máxima (W)	559.8567
Células por Módulo (Ncell)	66
Tensão de Circuito Aberto Voc (V)	47.42
Corrente de Curto-Circuito Isc (A)	15.0
Tensão no Ponto de Máxima Potência Vmp (V)	39.51
Corrente no Ponto de Máxima Potência Imp (A)	14.17
Coefficiente de Temperatura de Voc (%/°C)	-0.25
Coefficiente de Temperatura de Isc (%/°C)	0.102

Fonte: Elaborado pelo autor.

Para proteger o sistema contra pontos quentes (hot spots), foi modelado o diodo de Bypass. Seus parâmetros são apresentados na Tabela 8.

Tabela 8 – Parâmetros do Diodo de Bypass

Parâmetro	Valor
Resistência $R_{on}$ (Ohms)	0.001
Indutância $L_{on}$ (H)	0
Tensão de Condução $V_f$ (V)	0.7
Corrente Inicial $I_c$ (A)	0
Resistência do Snubber $R_s$ (Ohms)	inf
Capacitância do Snubber $C_s$ (F)	inf

Fonte: Elaborado pelo autor.

Por fim, outros blocos foram utilizados para realizar a medição dos valores de corrente e tensão, bem como para gerar os gráficos das curvas  $I - V$  e  $P - V$ . Esses gráficos são fundamentais para analisar o desempenho do módulo fotovoltaico, verificando seu comportamento sob diferentes condições de operação.

### 4.3 Implementação de Falhas

No presente trabalho, adotou-se a abordagem de variar a temperatura de 20°C a 35°C, com incremento de 1°C, testando todas as falhas. A utilização dessa faixa de temperatura é normalmente a variação na região nordeste.

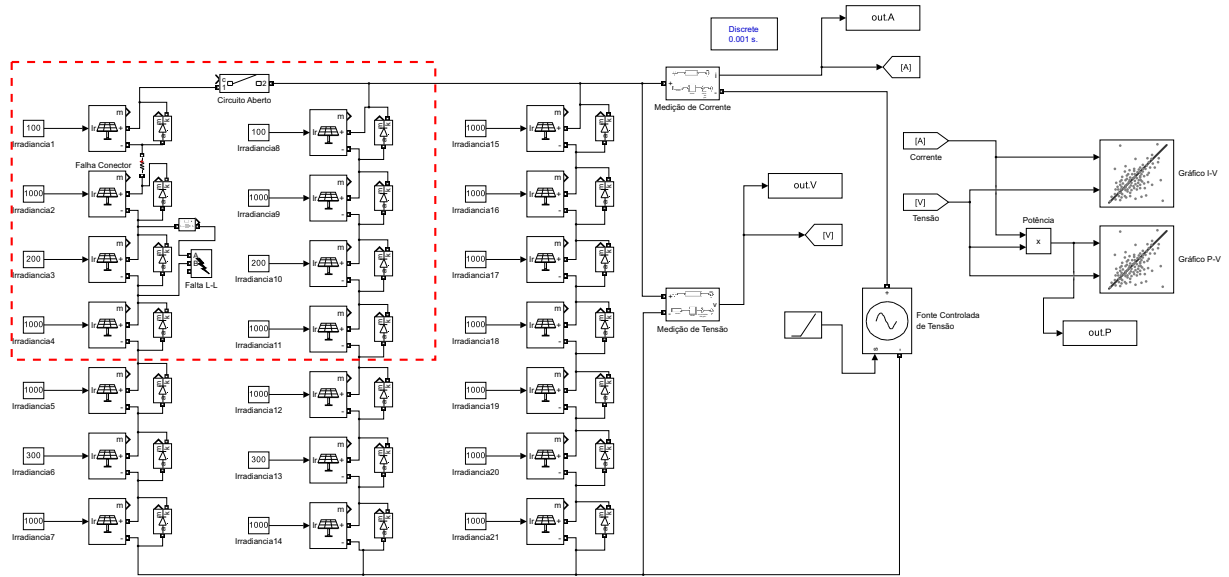
Em relação à irradiância dos módulos, foram considerados valores variando de 700 a 1000 W/m<sup>2</sup>, com incrementos de 10, 20 e 30 W/m<sup>2</sup>, conforme o banco de dados descrito na subseção 3.3.2. Essa faixa de operação é considerada adequada para o levantamento das curvas  $I - V$  em campo. A Figura 9 apresenta o modelo da implementação das falhas, como exemplo o 3 String, utilizando o ambiente Simulink.

#### 4.3.1 Circuito Aberto

A falha de circuito aberto é simulada pela desconexão entre dois pontos do circuito, representando uma interrupção na continuidade da corrente elétrica. Esse tipo de falha é descrito na subseção 3.2.1, onde se discutem os impactos de interrupções no funcionamento de sistemas fotovoltaicos.

Para reproduzir essa condição no Simulink, utiliza-se o bloco denominado "Breaker", que simula o comportamento de um disjuntor ao abrir o circuito. Como ilustrado na Figura 9, a abertura ocorre diretamente na String, desconectando uma das séries de módulos fotovoltaicos. O bloco "Breaker" funciona interrompendo o fluxo de corrente quando acionado, permitindo a análise do comportamento do sistema sob condições de falha.

Figura 9 – Modo de Implementação das Falhas no Matlab/Simulink.



Fonte: Elaborado pelo autor.

Essa falha será aplicada apenas no modelo simulado de 3 Strings. Isso se deve ao fato de que, no modelo de 1 String, uma falha de circuito aberto resultaria em valores de corrente e potência iguais a zero.

#### 4.3.2 Sombreamento Parcial

Para simular falhas de sombreamento parcial, reduz-se a irradiância aplicada aos módulos fotovoltaicos, representando condições de sombreamento que afetam a geração de energia. Foram realizadas simulações para dois cenários: sistemas com 1 String e com 3 Strings.

No modelo com apenas 1 String, a irradiância foi ajustada de forma desigual nos módulos, para simular diferentes níveis de sombreamento. Especificamente, aplicou-se:

- 100 W/m<sup>2</sup> no módulo 1,
- 200 W/m<sup>2</sup> no módulo 3,
- 300 W/m<sup>2</sup> no módulo 6.

No modelo com 3 Strings, os níveis de irradiância foram distribuídos entre os módulos de cada String, representando condições de sombreamento em diferentes regiões do sistema. Os valores aplicados foram:

- 100 W/m<sup>2</sup> nos módulos 1, 8 e 15,
- 200 W/m<sup>2</sup> nos módulos 3, 10 e 17,



- **300 W/m<sup>2</sup> nos módulos 6, 13 e 20.**

Essa modelagem permite analisar os impactos do sombreamento parcial no desempenho do sistema fotovoltaico, avaliando a queda de potência gerada e a redistribuição de corrente entre os módulos e Strings. A abordagem reflete diferentes condições de operação e contribui para o estudo de estratégias de mitigação.

### 4.3.3 Curto Linha-Linha

Em relação ao curto de Linha-Linha, conforme descrito na subseção 3.2.2, foi implementado um bloco de curto entre os pontos *A* e *B*, como ilustrado na Fig. 9.

Para os modelos do sistema com 1 e 3 Strings, a falha foi simulada entre os módulos 2-3, bem como entre os módulos 6-7, em ambos os casos.

### 4.3.4 Falha Conector

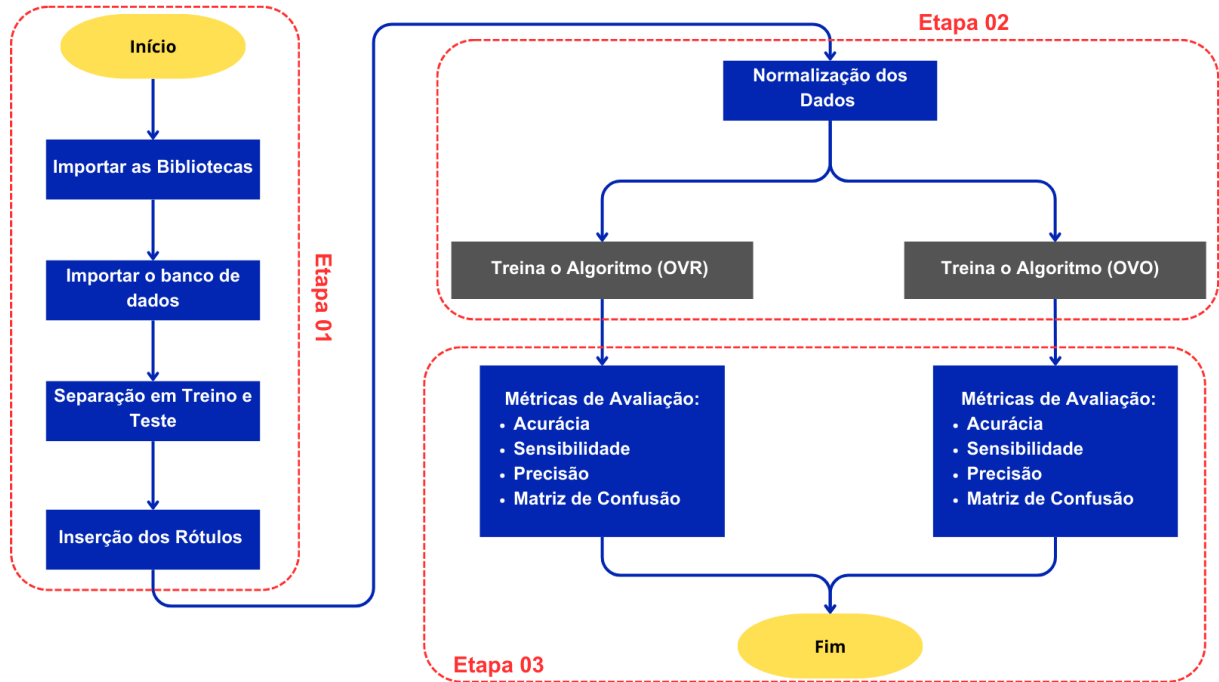
Por fim, a falha no conector é uma das principais causas de danos em usinas fotovoltaicas e pode comprometer seriamente o desempenho do sistema (HOJABRI *et al.*, 2022).

No modelo simulado com 1 String, adicionou-se resistências em série de 1, 2 e 3  $\Omega$  entre os módulos 1-2, 3-4 e 6-7, respectivamente. Para o modelo com 3 Strings, as resistências aplicadas foram: 1  $\Omega$  entre os módulos 1-2 e 6-7, 2  $\Omega$  entre os módulos 9-10 e 11-12, e 3  $\Omega$  entre os módulos 16-17 e 19-20. A Fig. 9 apresenta a implementação do circuito no Matlab/Simulink, destacando as falhas simuladas.

## 4.4 Algoritmo do Método Proposto

O método desenvolvido para classificação de falhas do sistema fotovoltaico, dividiu-se a criação do código em Python em três etapas, conforme apresenta na Fig. 10.

Figura 10 – Fluxograma do Algoritmo em Python.



Fonte: Elaborado pelo autor.

Na etapa 01, são realizados cinco procedimentos principais. O primeiro consiste na importação das bibliotecas necessárias; em seguida, ocorre a importação do banco de dados. Posteriormente, realiza-se a separação das amostras em conjuntos de treino e teste. Por fim, são inseridos os rótulos correspondentes ao tipo de condição do sistema, seja normal ou de falha.

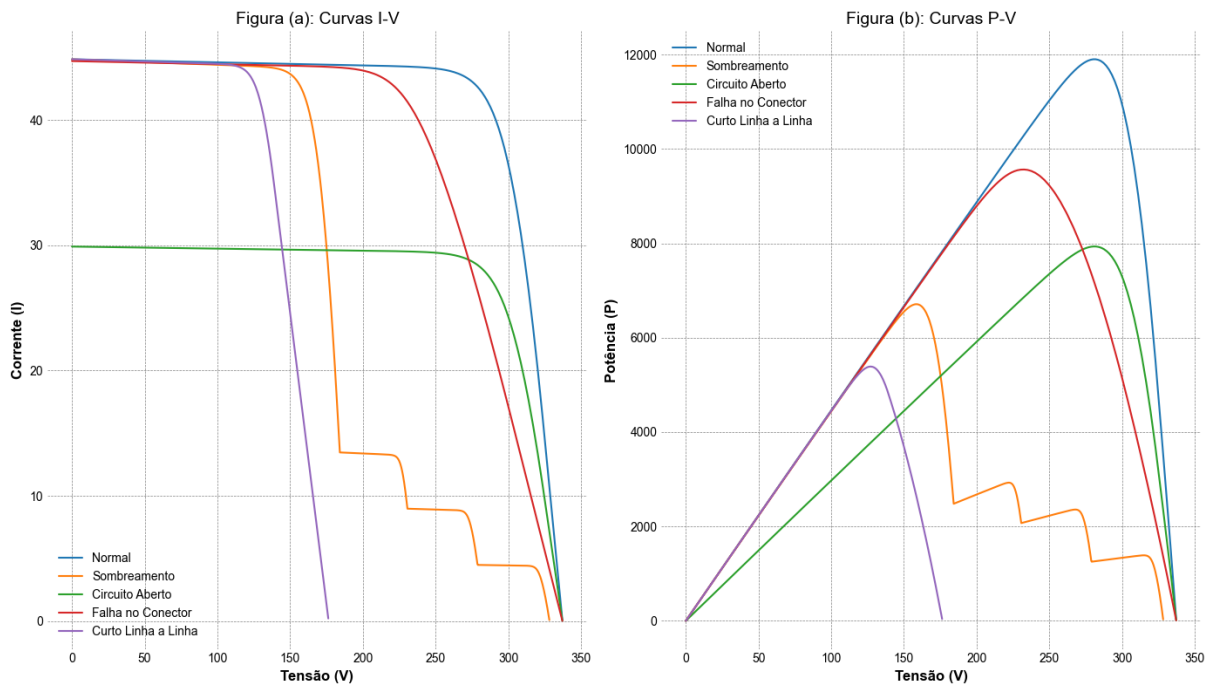
Na etapa 02, realiza-se a normalização dos dados e o treinamento do algoritmo utilizando ambas as estratégias de classificação multiclasse: *OVR* e *OVO*.

Por fim, na etapa 03, após o processo de treinamento e teste, são calculadas as métricas de avaliação, acurácia, precisão e sensibilidade, além da matriz de confusão, que permite identificar os acertos e erros do método.

## 5 Resultados e Discussões

Nesta etapa, será apresentado os resultados e análise da *UFV* para condições normais e de falhas. As falhas implementadas foram descritas na seção 4.3. A Fig. 11 apresenta o comportamento das curvas em relação as condições normais e de falhas.

Figura 11 – Comparação das Condições Normais e de Falhas.



As curvas demonstram claramente o impacto de diferentes tipos de falhas no comportamento elétrico de sistemas fotovoltaicos. A análise desses resultados oferece subsídios importantes para o diagnóstico e a detecção de falhas.

Na Figura (a), apresentado na Fig. 11, na cor azul, apresenta a característica esperada de um sistema fotovoltaico em condições ideais, com corrente máxima ( $I_{m\acute{a}x}$ ) e tensão máxima ( $V_{m\acute{a}x}$ ) próxima ao ponto de curto circuito. A curva  $P - V$ , na Figura (b), exibe um único Ponto de Máxima Potência ( $MPP$ ).

A falha no conector, curva vermelha, reduz a corrente máxima, devido ao aumento na resistência de contato ou à interrupção parcial no fluxo de corrente, apresentado na Figura (a). Na curva  $P - V$ , na Figura (b), há uma queda notável na potência máxima gerada, caracterizando um impacto moderado no desempenho.

Em condições de sombreamento, curva laranja, Figura (a), observa-se a formação de múltiplos "degraus" na curva  $I - V$ . Esses degraus correspondem às diferentes strings ou células afetadas de forma desigual pela incidência de sombras, resultando na redução da

corrente total do sistema. Na curva  $P - V$ , Figura (b), esse comportamento se reflete pela presença de múltiplos picos de potência, dificultando a localização do  $MPP$  e impactando negativamente a eficiência do sistema.

O curto circuito Linha-Linha, curva roxa, Figura (a), causa uma redução abrupta na tensão e corrente simultaneamente. No gráfico I-V, a curva converge rapidamente para valores próximos a zero, enquanto no gráfico  $P - V$ , Figura (b), a potência é reduzida drasticamente, conforme ilustrado na Fig. 9.

Na presença de falha de circuito aberto, curva verde, Figura (a), a corrente elétrica é reduzida, enquanto a tensão permanece próxima ao valor de condição normal. Em relação a curva  $P - V$ , apresenta uma redução de potência, devido a ausência de contribuição da String afetada.

## 5.1 Resultado da Classificação Utilizando 1 String

Nesta etapa, o banco de dados total contém 3.712 amostras, obtidas a partir de quatro condições de operação: condição normal, curto-circuito linha-linha, sombreamento e falha no conector, conforme descrito na Seção 4.3.

Os dados foram divididos em subconjuntos de 704, 1024 e 1984 amostras, com o objetivo principal de verificar o desempenho do método para diferentes volumes de dados.

Em relação aos resultados de classificação, apresentados na Tabela 9, os valores obtidos foram satisfatórios, uma vez que as métricas de avaliação indicaram acurácia de 100% tanto para a estratégia *OVR* quanto para *OVO*, no conjunto com 704 amostras. Além disso, a menor acurácia observada foi de 99,03%, no conjunto com 1024 amostras, utilizando a técnica *OVO*.


Tabela 9 – Métricas de desempenho para configuração com 1 String.

Métricas	Técnica OVR			Técnica OVO		
	704	1024	1984	704	1024	1984
Acurácia(%)	100	99,67	99,83	100	99,03	99,83
Sensibilidade (%)	100	99,67	99,83	100	99,03	99,83
Precisão (%)	100	99,68	99,83	100	99,05	99,83

Verifica-se que, utilizando ambas as técnicas de classificação, os resultados foram excelentes, com médias de acurácia, considerando os diferentes volumes de dados, de 99,83% para o *OVR* e 99,62% para o *OVO*.

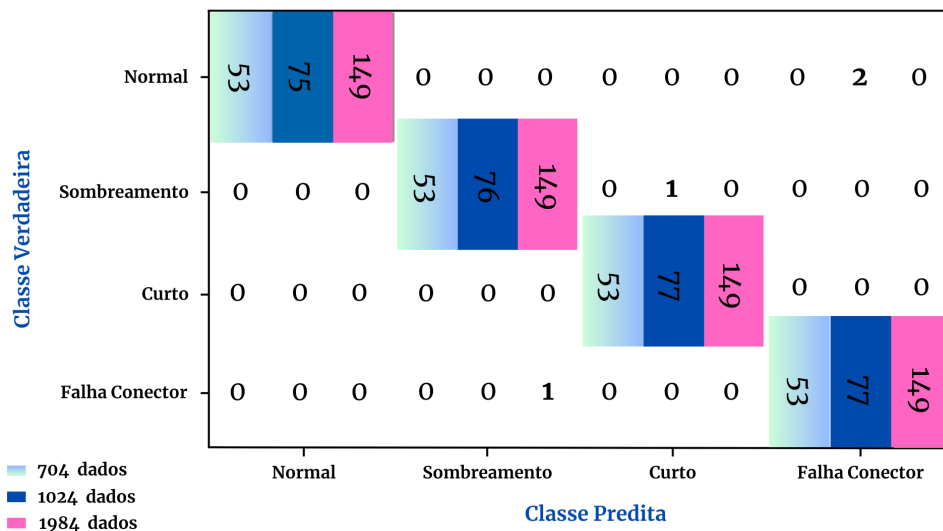
A matriz de confusão, apresentada na Fig. 12 e 13, mostra o número de erros e acertos que o método apresentou na classificação para os diferentes volumes de dados e configuração de operação, utilizando as técnicas *OVR* e *OVO*, respectivamente.

Figura 12 – OVR - Matriz de Confusão 1 String



Fonte: Elaborado pelo autor.

Figura 13 – OVO - Matriz de Confusão 1 String



Fonte: Elaborado pelo autor.

## 5.2 Resultado da Classificação Utilizando 3 String

Nesta etapa, foi utilizado o modelo com 3 strings, conforme ilustrado na Figura 8. Foram utilizadas 4.649 amostras, e a classificação foi realizada em cinco categorias: condição normal, sombreamento, falha de conector, curto-circuito linha-linha e circuito aberto.

O banco de dados foi dividido, assim como na configuração com 1 string, em três conjuntos contendo 880, 1280 e 2480 amostras, respectivamente.

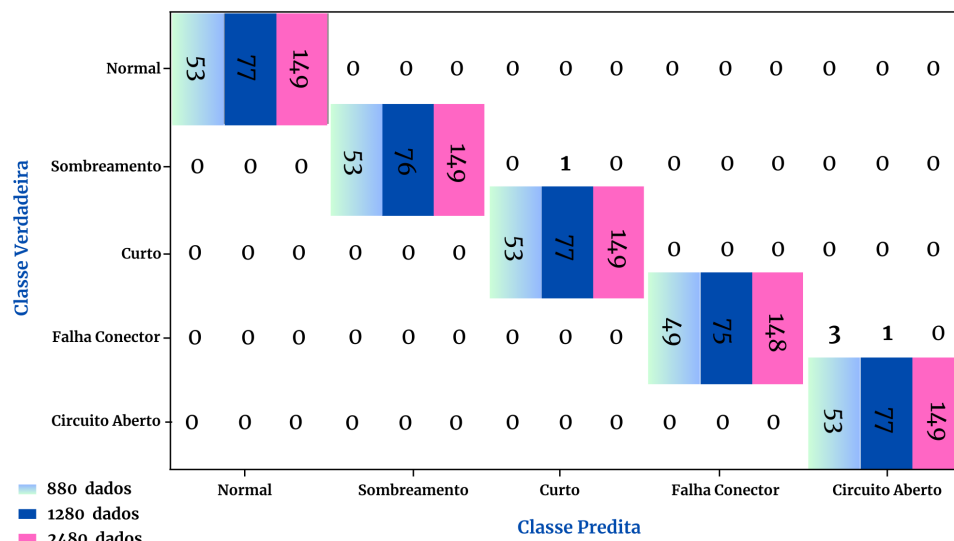
Em relação às métricas de desempenho, os resultados foram satisfatórios, com acurácias semelhantes para ambas as técnicas, *OVR* e *OVO*, conforme apresentado na Tabela 10, com destaque para a configuração com 3 strings no subconjunto de 880 amostras, onde foi observada a diferença entre os métodos. .

Tabela 10 – Métricas de desempenho para configuração com 3 String.

Métricas	Técnica OVR			Técnica OVO		
	880	1280	2480	880	1280	2480
Acurácia (%)	98,86	99,48	100	97,35	99,48	100
Sensibilidade (%)	98,86	99,48	100	97,35	99,48	100
Precisão (%)	98,93	99,49	100	97,35	99,48	100

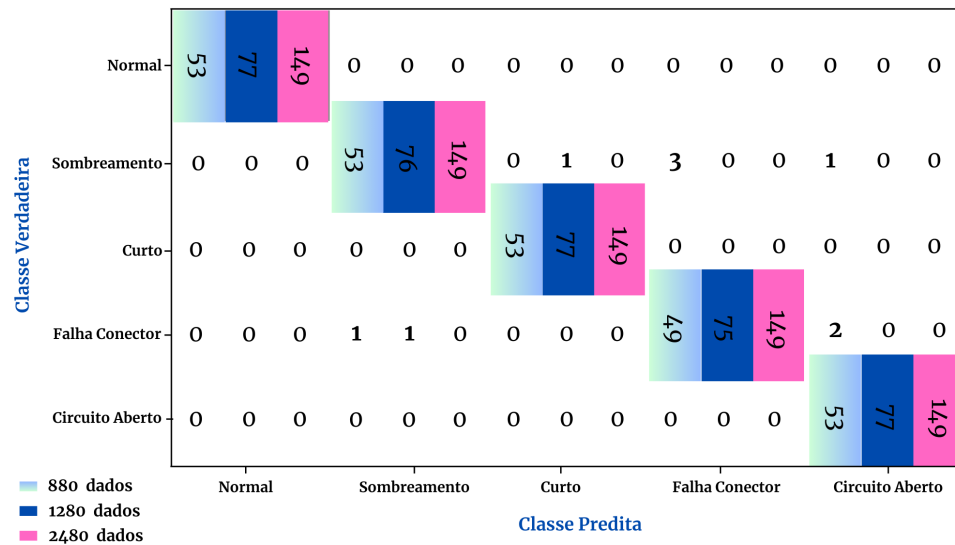
A matriz de confusão, apresentada na Fig. 14 e 15, mostra os resultados para *OVR* e *OVO*, respectivamente, considerando os diferentes subconjuntos de dados.

Figura 14 – OVR - Matriz de Confusão 3 String



Fonte: Elaborado pelo autor.

Figura 15 – OVO - Matriz de Confusão 3 String



Os valores apresentados nas Figuras 12, 13, 14 e 15 correspondem às matrizes de confusão obtidas para as diferentes configurações e subconjuntos de dados. Os números localizados na diagonal principal representam a quantidade de amostras corretamente classificadas, de acordo com a configuração de simulação. Já os valores fora da diagonal principal indicam os casos em que a classe prevista difere da classe verdadeira.

Em geral, a técnica *OVR* apresenta melhor desempenho quando se utiliza um maior volume de dados, uma vez que requer um número reduzido de classificadores. No presente trabalho, essa abordagem também demonstrou uma ligeira superioridade em termos de acurácia média em comparação à técnica *OVO*.

O tempo de treinamento, utilizando como exemplo as quantidades de amostras de 1984 e 2480 para as configurações com 1 e 3 strings, respectivamente, está apresentado na Tabela 11.

Tabela 11 – Tempo de treinamento, em milissegundos, para diferentes volumes de amostras.

Configuração	Número de Amostras	OVR	OVO
1 String	1,984	167 (ms)	135 (ms)
3 String	2,480	227 (ms)	236 (ms)

## 6 Conclusão

Neste trabalho, foram simuladas falhas em uma usina fotovoltaica utilizando o Matlab/Simulink 2023b. Foi desenvolvida uma análise do lado da Corrente Contínua e realizada a classificação dessas falhas utilizando técnica de aprendizado de máquina.

Problemas em usinas fotovoltaicas podem causar prejuízos técnicos e econômicos significativos. Portanto, é fundamental desenvolver metodologias de padronização, classificação, e detecção de falhas para auxiliar as empresas no processo de comissionamento, eficiência e no planejamento de operação e manutenção.

Os modelos simulados baseia-se em uma usina real, instalada na cidade de Pesqueira, Pernambuco, com potência de  $11,76 \text{ kWp}$ . A metodologia de análise considerou diversas condições de temperatura, irradiância e diferentes volumes de amostras, a fim de aumentar a robustez do método e possibilitar sua aplicação em outros sistemas instalados.

Os resultados das curvas  $I - V$  e  $P - V$  apresentaram características distintas para diferentes condições de funcionamento, conforme esperado. A falha menos prejudicial ao sistema é a de conector, mas se persistir e não for detectada, pode evoluir para uma falha de circuito aberto, mais severa, ou até causar arcos fotovoltaicos e incêndios. Por outro lado, a falha mais prejudicial é o curto circuito, que resulta em uma redução abrupta de corrente, tensão e, conseqüentemente, da potência de entrada do inversor.

A falha de sombreamento apresenta diversos possíveis pontos de máxima potência, dificultando muitas vezes o processo de operação no ponto de máxima potência do sistema. Essa falha, por sua vez, possui um maior diferencial nas características, apresentando uma espécie de escada. Em relação a falha de circuito aberto ocorre uma redução na corrente e potência do sistema apresentado no trabalho.

Na configuração com uma String, considerando os conjuntos com 704, 1.024 e 1.984 amostras, a técnica One-vs-Rest (*OVR*) alcançou uma acurácia média de 99,83%, enquanto a técnica One-vs-One (*OVO*) obteve uma média de 99,62%.

Já na configuração com três Strings, utilizando subconjuntos de 880, 1.280 e 2.480 amostras, a técnica *OVR* alcançou uma média de 99,46% de acurácia, ao passo que a técnica *OVO* obteve uma acurácia média ligeiramente superior, de 99,94%. A matriz de confusão, em ambos os casos, apresenta o total de erros de classificação, sendo registrada uma soma de 6 erros para o sistema com uma String e 14 erros para o sistema com três Strings.

Na literatura existem diversos estudos relacionado a classificação de falhas, mas não contém muitos estudos que levem em consideração questões ambientais, relaciona



com o comissionamento, analisam as falhas com diversas condições de temperatura e irradiância, bem como utilização de técnicas de análise multiclasse. Além disso, o presente trabalho apresenta e classifica falhas elétrica, físicas e ambientais que ocorrem em *UFV* utilizando uma metodologia adequada quando se trata de problemas com muitas classes.

Como sugestões para trabalhos futuros, recomenda-se:

- Testar a técnica de classificação utilizada com dados reais ou híbridos para avaliar a performance do método proposto;
- Implementar mais tipos de falhas no sistema, incluindo falhas no lado de Corrente Alternada (*CA*);
- Integrar a técnica a uma estrutura de medição física em campo para levantamento das curvas  $I - V$  e  $P - V$ ;
- Otimizar o método de levantamento das curvas  $I - V$  e  $P - V$  para permitir a detecção e classificação de falhas em tempo real;
- Implementar um sistema de monitoramento contínuo baseado em redes neurais para prever falhas antes que causem impacto significativo no sistema.

# Referências

- ALI, Q. *et al.* A machine-learning-based robust classification method for pv panel faults. *Sensors*, IEEE, v. 22, p. 8515, 2022. Citado na página 31.
- ALJAFARI, S. *et al.* Supervised classification and fault detection in grid-connected pv systems using 1d-cnn: Simulation and real-time validations. *Energy Reports*, IEEE, 2024. Citado na página 22.
- ALSUDI, A.-A. M.; K. Deep learning based fault classification and location for photovoltaic systems. *2023 16th International Conference*, IEEE, 2023. Citado na página 22.
- AMIRI, O. *et al.* Faults detection and diagnosis of pv systems based on machine learning approach using random forest classifier. *Energy Conversion and Management*, IEEE, 2024. Citado na página 23.
- ANEEL. *Resolução Normativa nº 1.000/2021*. 2021. Resolução Normativa da Agência Nacional de Energia Elétrica (ANEEL). Disponível em: <<https://www2.aneel.gov.br/cedoc/ren20211000.html>>. Acesso em: 22 jan 2025. Citado na página 25.
- ANEEL. *Matriz Elétrica Brasileira*. 2025. Relatório técnico da EPE. Disponível em: <<https://www.gov.br/secom/pt-br/assuntos/noticias/2025/janeiro/matriz-eletrica-brasileira-registra-maior-expansao-da-historia-em-2024>>. Acesso em: 22 jan 2025. Citado 2 vezes nas páginas 11 e 26.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR-16.274*: Sistemas fotovoltaicos - requisitos de comissionamento, inspeção e ensaios. Rio de Janeiro, 2014. Citado 3 vezes nas páginas 12, 28 e 34.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR-16.690*: Instalações elétricas de arranjos fotovoltaicos requisitos de projeto. Rio de Janeiro, 2019. 75 p. Citado na página 28.
- BADR, H. *et al.* Fault identification of photovoltaic array based on machine learning classifiers. *IEEE POWER AND ENERGY SOCIETY SECTION*, IEEE, 2024. Citado na página 21.
- BOUGOFFA, B. *et al.* Fault identification of photovoltaic array based on machine learning classifiers. *2024 International Conference on Decision Aid Sciences and Applications (DASA)*, IEEE, 2024. Citado na página 23.
- CARDINALE, C. *et al.* Quantitative comparison of infrared thermography, visual inspection, and electrical analysis techniques on photovoltaic modules: A case study. *Energies*, v. 14, p. 1841, 2022. Citado na página 19.
- CASSINI, C. *et al.* Analysis of the soiling effects on commissioning of photovoltaic systems: Short-circuit current correction. In: *Congresso Brasileiro de Energia Solar (CBENS)*. [S.l.: s.n.], 2022. p. 1–8. Citado na página 18.

- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *ACM. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. p. 785–794. Disponível em: <<https://doi.org/10.1145/2939672.2939785>>. Citado na página 39.
- COSTA, M. *et al.* A comparison of machine learning-based methods for fault classification in photovoltaic systems. *IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*, IEEE, 2019. Citado na página 21.
- EPE. *Balanco Energético Nacional 2023: Ano base 2022*. 2023. Relatório técnico da EPE. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Balanco-Energetico-Nacional-2023>>. Acesso em: 22 jan 2025. Citado na página 11.
- GINU *et al.* Análise comparativa entre geração fotovoltaica em usinas de pequeno e médio porte em funcionamento utilizando tecnologias de inversores do tipo string e microinversores – casos reais. In: *REVISTA FOCO*. [S.l.: s.n.], 2024. Citado na página 26.
- GOKGOZ *et al.* Challenges during commissioning and operation in photovoltaic power plants by electrical faults. *Turkish Journal of Electromechanics & Energy*, v. 8, p. 37–44, 2023. Citado 2 vezes nas páginas 12 e 20.
- GOKGOZ *et al.* Investigation of failures during commissioning and operation in photovoltaic power systems. *Applied Sciences*, v. 14, p. 2083, 2024. Citado 4 vezes nas páginas 20, 28, 30 e 31.
- HASTIE *et al.* *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd. ed. New York: Springer, 2009. Citado na página 37.
- HOJABRI, K. *et al.* Iot-based pv array fault detection and classification using embedded supervised learning methods. *IEEE Transactions on Power Delivery*, IEEE, v. 15, p. 2097, 2022. Citado 4 vezes nas páginas 12, 13, 31 e 48.
- MELIT, C.; KALOGIROU, G. A comparison of machine learning-based methods for fault classification in photovoltaic systems. *Renewable Energy*, IEEE, 2022. Citado na página 22.
- MOHAMMADREZA *et al.* Aerial infrared thermography for low-cost and fast fault detection in utility-scale pv power plants. *Solar Energy*, IEEE, p. 712–724, 2020. Citado na página 18.
- PDE. *Matriz Elétrica Brasileira*. 2031. Plano Decenal de Expansão de Energia. Disponível em: <[https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-607/topico-637/PDE%202031\\_RevisaoPosCP\\_rvFinal\\_v2.pdf](https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-607/topico-637/PDE%202031_RevisaoPosCP_rvFinal_v2.pdf)>. Acesso em: 22 jan 2025. Citado na página 11.
- PIMENTEL, C. *et al.* Problemas em instalações fotovoltaicas de micro e minigeração: Por que ocorrem e como prevenir? In: *Congresso Brasileiro de Energia Solar (CBENS)*. [S.l.: s.n.], 2022. Citado 2 vezes nas páginas 19 e 27.
- SANTOS, C. *et al.* Contornando as limitações da nbr-16274:2014 na avaliação de desempenho e no ajuste das simulações de sistemas fotovoltaicos de pequeno e médio porte. In: *Congresso Brasileiro de Energia Solar (CBENS)*. [S.l.: s.n.], 2022. Citado 4 vezes nas páginas 19, 28, 43 e 44.

SUMILAN *et al.* A comparison of machine learning-based methods for fault classification in photovoltaic systems. *Sustainability*, MDPI, 2024. Citado na página 24.

TAREK, M. *et al.* Machine learning-based condition monitoring for pv systems: State of the art and future prospects. *Energies*, IEEE, v. 14, p. 6316, 2021. Citado na página 31.

WESTON, J.; WATKINS, C. Support vector machines for multi-class pattern recognition. *European Symposium on Artificial Neural Network*, D-Facto public, 1999. Citado na página 37.

ZHANG. Long short-term memory networks based automatic feature extraction for photovoltaic array fault diagnosis. *IEEE Access*, IEEE, v. 7, p. 8515, 2020. Citado na página 31.

ZHU, Y. An adaptive i-v curve detecting method for photovoltaic modules. *2018 IEEE International Power Electronics and Application Conference and Exposition (PEAC)*, IEEE, p. 1–6, 2019. Citado na página 18.