

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA – PPGEEL

MARCOS EDUARDO TRETER

DIAGNÓSTICO INTELIGENTE DA GERAÇÃO EM USINAS FOTOVOLTAICAS
EMPREGANDO TRAÇADOR DE CURVAS I-V

JOINVILLE

2023

MARCOS EDUARDO TRETER

**DIAGNÓSTICO INTELIGENTE DA GERAÇÃO EM USINAS FOTOVOLTAICAS
EMPREGANDO TRAÇADOR DE CURVAS I-V**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Prof. Dr. Marcello Mezaroba

Coorientador: Prof. Dr. Leandro Michels

JOINVILLE

2023

**Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Setorial do CCT/UDESC,
com os dados fornecidos pelo(a) autor(a)**

Treter, Marcos Eduardo
DIAGNÓSTICO INTELIGENTE DA GERAÇÃO EM
USINAS FOTOVOLTAICAS EMPREGANDO TRAÇADOR DE
CURVAS I-V / Marcos Eduardo Treter. -- 2023.
180 p.

Orientador: Marcello Mezaroba
Coorientador: Leandro Michels
Tese (doutorado) -- Universidade do Estado de Santa
Catarina, Centro de Ciências Tecnológicas, Programa de
Pós-Graduação em Engenharia Elétrica, Joinville, 2023.

1. Detecção de falhas. 2. Monitoramento fotovoltaico. 3.
Sistemas fotovoltaicos. I. Mezaroba, Marcello. II. Michels,
Leandro. III. Universidade do Estado de Santa Catarina,
Centro de Ciências Tecnológicas, Programa de
Pós-Graduação em Engenharia Elétrica. IV. Título.

MARCOS EDUARDO TRETER

**DIAGNÓSTICO INTELIGENTE DA GERAÇÃO EM USINAS FOTOVOLTAICAS
EMPREGANDO TRAÇADOR DE CURVAS I-V**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

BANCA EXAMINADORA:

Prof. Dr. Marcello Mezaroba
Universidade do Estado de Santa Catarina – UDESC

Membros:

Prof. Dr. Marcello Mezaroba
Universidade do Estado de Santa Catarina – UDESC

Prof. Dr. Alessandro Luiz Batschauer
Universidade do Estado de Santa Catarina – UDESC

Prof. Dr. Sérgio Vidal Garcia Oliveira
Universidade do Estado de Santa Catarina – UDESC

Prof. Dr. Claiton Moro Franchi
Universidade Federal de Santa Maria – UFSM

Prof. Dr. Fabrício Bradaschia
Universidade Federal de Pernambuco – UFPE

Joinville, 07 de março de 2023

Dedico esta tese de doutorado aos meus pais que, desde cedo, me ensinaram o valor da educação para se entender o mundo e por serem um pilar da minha formação como ser humano. Também dedico esta tese à minha esposa cuja presença foi essencial para a conclusão deste projeto.

AGRADECIMENTOS

Agradeço aos meus pais Tânia Cristine Simon e Marcos Rogério Treter pelo carinho, apoio e incentivo que serviram de alicerce para as minhas realizações. Além dos esforços que foram investidos para me proporcionar um ensino de qualidade durante todo o meu período escolar. Amo vocês!

Agradeço à minha esposa Carolina Backes pelo seu amor e pela sua compreensão. Obrigado por me proporcionar momentos incríveis ao seu lado. Te amo!

Agradeço ao meu orientador, professor Marcello Mezaroba, pela confiança depositada na minha proposta de projeto e pelas contribuições dadas durante o processo.

Agradeço ao professor Leandro Michels, coorientador deste trabalho, pelas contribuições e ensinamentos que guiaram o meu aprendizado ao longo do curso de graduação, do mestrado e do doutorado. Obrigado pelos seus conselhos professor!

Agradeço aos amigos do Instituto de Redes Inteligentes Charles Schardong, Henrique Horst, Igor Bitencourt e Paulo Roberto Machado. Vocês desempenharam um papel significativo na elaboração desta tese.

Agradeço pela amizade e dedico este trabalho ao meu amigo Lincon Turcato Carabagialle (*in memoriam*).

Por fim, agradeço a todos que participaram de forma direta ou indiretamente do desenvolvimento desta tese.

“Não é na ciência que está a felicidade, mas na aquisição da ciência.” (Edgar Allan Poe)

RESUMO

Os sistemas fotovoltaicos destacam-se entre as fontes geradoras de energia elétrica devido a sua característica renovável, longa vida útil, necessidade de pouca manutenção, operação silenciosa e limpa. No entanto, também enfrentam algumas adversidades, como a característica intermitente, a baixa densidade de energia, os custos elevados de instalação e a alta dependência das condições climáticas. Portanto, são sistemas que necessitam de serviços adequados de Operação e Manutenção (O&M) para que se mantenham com níveis satisfatórios de desempenho técnico. Atualmente, a maior parte dos sistemas de monitoramento de usinas fotovoltaicas possuem dificuldades em diagnosticar as causas do baixo desempenho dessas plantas, o que causa um impacto significativo na lucratividade desses projetos. A solução proposta neste trabalho baseia-se em um traçador de curvas I-V com uma metodologia integrada para o diagnóstico da geração em usinas fotovoltaicas. A proposta possui o objetivo de resolver as principais carências dos sistemas comerciais de monitoramento de usinas. Os traçadores de curvas I-V são ferramentas que estão disponíveis comercialmente e o seu uso já integra os protocolos de O&M. Entretanto, esses equipamentos são manuais, necessitam de um tempo de configuração e expõem o operador a riscos letais de choque elétrico. Por outro lado, o traçador de curvas proposto é integrado à usinas e através de uma carga capacitiva permite rastrear automaticamente as curvas I-V de cada série fotovoltaica. O traçador possui uma metodologia para o diagnóstico da geração que está dividida em duas etapas. A primeira etapa é responsável por detectar o baixo desempenho de cada uma das séries fotovoltaicas que compõem a matriz e por quantificar as perdas. A identificação do baixo desempenho ocorre através da comparação entre a curva I-V mensurada em campo com a curva estimada por um modelo matemático. A segunda etapa é responsável por identificar os fatores de degradação e classificar a condição operacional da série fotovoltaica. Uma rede neural artificial do tipo *perceptron* multicamadas é utilizada para classificar as situações de sujidade, sombreamento e condução dos diodos de *by-pass*. Destaca-se que, o diagnóstico da geração pode ser acessado remotamente, o que viabiliza a operação adequada de usinas sem a necessidade de uma equipe de O&M em campo. Tanto o traçador de curvas I-V como a metodologia para diagnóstico da geração foram validados em uma usina fotovoltaica com potência nominal de 100 kW. Para o processo de validação, empregou-se um conjunto composto por 100 curvas I-V, as quais foram obtidas, pelo traçador de curvas proposto, em uma série fotovoltaica sob distintas condições operacionais. Deste conjunto, 70 curvas foram utilizadas no treinamento da rede neural e as demais na etapa de validação. A rede apresentou a acurácia de 0,989, a precisão de 0,978 e a revocação de 1,0.

Palavras-chave: Detecção de falhas. Monitoramento fotovoltaico. Sistemas fotovoltaicos.

ABSTRACT

The photovoltaic systems stand out among the sources of electricity due to their renewable characteristic, long service life, need for little maintenance, silent and clean operation. However, they also faces some adversities, such as the intermittent characteristic, low energy density, high installation costs and high dependence on weather conditions. Therefore, they are systems that require adequate Operation and Maintenance (O&M) services in order to maintain satisfactory levels of technical performance. Nowadays, most solar power plants monitoring systems have difficulties in diagnosing the causes of low performance of these plants, which causes a significant impact on projects profitability. The solution proposed in this work is based on an I-V curve tracer with an integrated methodology for the diagnosis of generation in solar power plants. The proposal aims to solve the shortcomings of commercial monitoring systems. I-V curve trace are commercially available tools that are already part of O&M protocols. However, these devices are manual, needs setup time and expose the operator to lethal risks of electric shock. On the other hand, the proposed curve tracer is integrated into the solar power plant and through a capacitive load allows automatically tracking the I-V curves of each photovoltaic string. The tracer has a methodology for generation diagnosis that is divided into two stages. The first is responsible for detecting the low performance of each photovoltaic strings and for quantifying the losses. This analysis occurs through the comparison between the I-V curve measured with the curve estimated by a mathematical model. The second stage is responsible for identifying the degradation factors and classifying the operational condition of the photovoltaic strings. A multilayer perceptron artificial neural network is used to classify the situations of dirt, shading and operation of by-pass diodes. The generation diagnosis can be accessed remotely, which makes it possible to operate the plant without O&M teams in the field. Both the I-V curve tracer and the generation diagnosis methodology were validated in a solar power plants with nominal power of 100 kW. For validation, a set of 100 I-V curves was used, these curves were obtained by the proposed I-V curve plotter under different operational conditions of a photovoltaic strings. Of this set, 70 curves were used in neural network training and the others in neural network validation. The network presented an accuracy of 0.989, a precision of 0.978 and a recall of 1.0.

Keywords: Fault detection. Photovoltaic monitoring. Photovoltaic systems.

LISTA DE ILUSTRAÇÕES

Figura 1 – Adição anual global de fontes renováveis separadas por tecnologias.	22
Figura 2 – Estrutura do trabalho.	48
Figura 3 – Influência da irradiação solar na curva I-V de um módulo fotovoltaico. . . .	49
Figura 4 – Classificação da radiação solar incidente sobre os módulos fotovoltaicos. . .	50
Figura 5 – Influência da temperatura de operação na curva I-V de um módulo fotovoltaico.	51
Figura 6 – Representação de um módulo parcialmente sombreado com um diodo de <i>by-pass</i> em condução.	54
Figura 7 – Exemplo de uma curva I-V típica.	62
Figura 8 – Composição da curva I-V de uma matriz fotovoltaica.	62
Figura 9 – Configuração para medir a curva I-V de séries fotovoltaicas em uma caixa de junção.	65
Figura 10 – Método da resistência variável para rastrear a curva I-V.	66
Figura 11 – Método da carga capacitiva para rastrear a curva I-V.	66
Figura 12 – Método da carga eletrônica para rastrear a curva I-V.	68
Figura 13 – Conversor c.c.-c.c. com topologia SEPIC para o rastreamento de curvas I-V.	68
Figura 14 – Fator de forma de uma curva I-V.	73
Figura 15 – Principais tipos de desvios que podem ocorrer em curvas I-V.	75
Figura 16 – Neurônio de uma rede neural artificial.	77
Figura 17 – Exemplo de uma rede neural artificial do tipo <i>perceptron</i> multicamadas. . .	78
Figura 18 – Modelo de diodo único com três parâmetros.	82
Figura 19 – Modelo de diodo único com quatro parâmetros.	82
Figura 20 – Modelo de diodo único com cinco parâmetros.	83
Figura 21 – Modelo de diodo duplo com sete parâmetros.	84
Figura 22 – Topologia do traçador de curvas I-V proposto.	90
Figura 23 – Topologia do módulo comutador.	92
Figura 24 – Placa eletrônica do módulo para comunicação via RS-485.	93
Figura 25 – Influência da indutância do cabo na desconexão de séries fotovoltaicas. . . .	94
Figura 26 – Circuito para o projeto térmico do dissipador.	96
Figura 27 – Protótipo do módulo comutador.	98
Figura 28 – Topologia do módulo para aquisição de curvas I-V.	99
Figura 29 – Diagrama de entradas e saídas do circuito de sensoriamento.	100
Figura 30 – Placa eletrônica do circuito de sensoriamento.	101
Figura 31 – Diagrama de entradas e saídas do circuito operacional.	102
Figura 32 – Placa eletrônica do circuito operacional.	103
Figura 33 – Placa eletrônica da carga capacitiva.	104
Figura 34 – Diagrama de entradas e saídas do circuito de processamento.	105
Figura 35 – Circuito de processamento do módulo para aquisição das curvas I-V.	106

Figura 36 – Fluxograma do algoritmo do circuito de processamento do traçador de curvas I-V.	107
Figura 37 – Protótipo do módulo para aquisição das curvas I-V.	108
Figura 38 – Placa eletrônica do circuito para medição da irradiância no plano inclinado.	110
Figura 39 – Ensaio para calibração e ajuste do circuito para medição da irradiância no plano inclinado.	110
Figura 40 – Placa eletrônica do circuito para medição da temperatura de operação dos módulos.	112
Figura 41 – Ensaio para calibração e ajuste do circuito para medição da temperatura de operação dos módulos.	112
Figura 42 – Protótipo do módulo para aquisição dos parâmetros climáticos.	113
Figura 43 – Protótipo do módulo controlador.	114
Figura 44 – Fluxograma da aplicação que controla a execução dos ensaios.	116
Figura 45 – Fluxograma da metodologia para diagnóstico da geração de usinas FV.	121
Figura 46 – Proposta de estrutura para o arquivo csv de uma curva I-V.	125
Figura 47 – Fluxograma do processo para estimação dos parâmetros do MGNL.	129
Figura 48 – Comparação entre curvas I-V mensuradas e modeladas pelo MGNL em Python.	132
Figura 49 – Relação entre os pontos de interesse medidos e modelados pelo MGNL.	133
Figura 50 – Impacto da sujidade e do sombreamento na curva I-V de uma série fotovoltaica.	136
Figura 51 – Estrutura da RNA proposta para identificar os fatores de degradação de uma série fotovoltaica.	138
Figura 52 – Fluxograma do algoritmo <i>backpropagation</i> aplicado no treinamento da RNA.	139
Figura 53 – Usina fotovoltaica localizada na Universidade Federal de Santa Maria.	143
Figura 54 – Traçador de curvas I-V integrado à usina fotovoltaica.	144
Figura 55 – Curvas I-V adquiridas pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.	146
Figura 56 – Conjunto de curvas I-V utilizado na estimação dos parâmetros do MGNL.	149
Figura 57 – As situações operacionais que foram analisadas em uma série fotovoltaica.	151
Figura 58 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 1/4.	154
Figura 59 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 2/4.	155
Figura 60 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 3/4.	156
Figura 61 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 4/4.	157
Figura 62 – Matrizes de confusão para a RNA proposta.	161

LISTA DE TABELAS

Tabela 1 – Publicações selecionadas que envolvem o projeto de traçadores de curvas I-V.	41
Tabela 2 – Síntese dos traçadores descritos nas publicações elencadas na Tabela 1. . . .	42
Tabela 3 – Patentes selecionadas que envolvem o projeto de traçadores de curvas I-V. .	43
Tabela 4 – Soluções comerciais para a aquisição de curvas I-V	70
Tabela 5 – Principais especificações técnicas do transistor IHW20N120R3.	95
Tabela 6 – Principais especificações técnicas do diodo DSEP30-12A.	95
Tabela 7 – Principais especificações técnicas do diodo 10A10.	95
Tabela 8 – Resultado do processo de calibração e ajuste do circuito para medição da corrente.	100
Tabela 9 – Resultado do processo de calibração e ajuste do circuito para medição da tensão.	101
Tabela 10 – Resultado do processo de calibração e ajuste do circuito para medição da irradiância no plano inclinado.	111
Tabela 11 – Resultado do processo de calibração e ajuste do módulo para medição da temperatura de operação dos módulos.	113
Tabela 12 – Limites e ponto inicial dos parâmetros a serem estimados pelo MGNL. . . .	130
Tabela 13 – Pontos de interesse de curvas I-V modeladas pelo MGNL em ambientes distintos.	131
Tabela 14 – Relações I_{scnorm} , V_{ocnorm} , I_{mpnorm} e V_{mpnorm} para as curvas I-V da Figura 50. . .	137
Tabela 15 – Especificações técnicas do módulo fotovoltaico CS6K-270P.	143
Tabela 16 – Condições climáticas durante os ensaios de validação do traçador de curvas I-V.	145
Tabela 17 – Corrente de curto-circuito adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.	147
Tabela 18 – Tensão de circuito aberto adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.	147
Tabela 19 – Potência máxima adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.	148
Tabela 20 – Condições climáticas do conjunto de curvas I-V da Figura 56.	149
Tabela 21 – Parâmetros estimados pelo MGNL.	150
Tabela 22 – Figuras de mérito do MGNL com base nos ensaios da Figura 48.	150
Tabela 23 – Parâmetros das curvas I-V apresentadas nas Figuras 58, 59, 60 e 61.	158

LISTA DE ABREVIATURAS E SIGLAS

AM	<i>Air mass</i> (Massa de ar)
ANFIS	<i>Adaptive neuro fuzzy inference system</i> (Sistema de inferência neuro-fuzzy adaptativo)
DAQ	<i>Data acquisition system</i> (Sistema de aquisição de dados)
E/S	Entradas/saídas
EL	Eletroluminescência
F.I.	Fator de impacto
FD	Fator de desempenho
FF	Fator de forma
FV	Fotovoltaico (a)
IA	Inteligência artificial
IEC	<i>International Electrotechnical Commission</i> (Comissão Eletrotécnica Internacional)
IGBT	<i>Insulated gate bipolar transistor</i> (Transistor bipolar de porta isolada)
INCT-GD	Instituto Nacional de Ciência e Tecnologia em Geração Distribuída de Energia Elétrica
INRI	Instituto de Redes Inteligentes
IoT	<i>Internet of things</i> (Internet das coisas)
LeTID	<i>Light elevated temperature induced degradation</i> (Degradação induzida por luz e temperatura elevada)
LID	<i>Light induced degradation</i> (Degradação induzida pela luz)
MGNL	Modelo global não-linear
MME	Média móvel exponencial
MOSFET	<i>Metal oxide semiconductor field effect transistor</i> (Transistor de efeito de campo semicondutor de óxido metálico)
O&M	Operação e manutenção
PERC	<i>Passivated Emitter Rear Cell</i> (Emissor passivado e contato traseiro)
PID	<i>Potential induced degradation</i> (Degradação induzida por potencial)
PLC	<i>Power line communication</i> (Comunicação via rede elétrica)
PR	<i>Performance ratio</i> (Taxa de desempenho)
PS	<i>Pattern search</i> (Busca por padrões)

PTC	<i>PV-USA test conditions</i> (Condições de teste PV-EUA)
RCD	Resistor, capacitor e diodo
RNA	Rede neural artificial
SEPIC	<i>Single-ended primary-inductor converter</i> (Conversor com indutância simples no primário)
STC	<i>Standard test conditions</i> (Condição padrão de teste)
TW	Transformadas Wavelets
UDESC	Universidade do Estado de Santa Catarina
UPS	<i>Uninterruptible Power Supply</i> (Fonte de alimentação ininterrupta)
UFSC	Universidade Federal de Santa Maria
UV	Ultravioleta
VANT	Veículo aéreo não tripulado

LISTA DE SÍMBOLOS

A	Ampère
A	Fator de idealidade
A_{ref}	Fator de idealidade de referência
a_r	Coefficiente de variação da resistência elétrica em função da temperatura
A/D	Analógico/Digital
Ac	Acurácia
C	Capacitância
$C_{a,i}$	Capacitores da carga capacitiva do traçador de curvas I-V
C_{Sn}	Capacitor do circuito de <i>snubber</i>
c.a.	Corrente alternada
c.c.	Corrente contínua
cm^3	Centímetro cúbico
D_1	Diodo do módulo comutador - conexão com o inversor fotovoltaico
D_2	Diodo do módulo comutador - conexão com o traçador de curvas
D_{Sn}	Diodo do circuito de <i>snubber</i>
d	Diâmetro
FN	Falsos negativos
FP	Falsos positivos
G_{con}	Irradiância solar no plano inclinado convertida
G_{med}	Irradiância solar no plano inclinado medida
G_{var}	Variação tolerável da irradiância
g	Gramas
$g(\cdot)$	Função de ativação de um neurônio
GW	Gigawatts
h	Hora
I	Corrente elétrica
I_{conv}	Corrente elétrica convertida
I_g	Corrente elétrica fotogerada
I_{med}	Corrente elétrica medida
I_{mp}	Corrente elétrica no ponto de máxima potência

$I_{mp_{med}}$	Corrente elétrica no ponto de máxima potência medida
$I_{mp_{mod}}$	Corrente elétrica no ponto de máxima potência modelada
$I_{mp_{norm}}$	Relação entre $I_{mp_{med}}$ e $I_{mp_{mod}}$
I_{sat}	Corrente elétrica de saturação reversa
I_{sc}	Corrente elétrica de curto-circuito
$I_{sc_{med}}$	Corrente elétrica de curto-circuito medida
$I_{sc_{mod}}$	Corrente elétrica de curto-circuito modelada
$I_{sc_{ref}}$	Corrente elétrica de curto-circuito de referência
$I_{sc_{norm}}$	Relação entre $I_{sc_{med}}$ e $I_{sc_{mod}}$
k	Constante de Boltzmann
kB	Quilobyte
kV	Quilovolt
L	Comprimento
L_{cabo}	Indutância do cabo
L.I.	Limite inferior
L.S.	Limite superior
M Ω	Megaohm
MHz	Megahertz
MW	Megawatts
m ²	Metro quadrado
mA	Miliampere
mm ²	Milímetro quadrado
ms	Milissegundo
N_s	Quantidade de células conectadas em série em um módulo fotovoltaico
nF	Nanofarad
P	Potência elétrica
P_{dis}	Potência elétrica dissipada
P_{max_dif}	Diferença entre a potência máxima medida e a potência máxima modelada
P_{max_lim}	Potência elétrica limiar
P_{max_med}	Potência elétrica máxima medida
P_{max_mod}	Potência elétrica máxima modelada

P_{max_perdas}	Perdas da geração fotovoltaica em potência elétrica
P_{mp}	Potência elétrica máxima
Pr	Precisão
q	Carga elétrica de um elétron
R	Resistência elétrica
R_{CD}	Resistência térmica entre o encapsulamento e o dissipador
R_{Da}	Resistência térmica entre o dissipador e o ambiente
R_{jC}	Resistência térmica entre a junção e o encapsulamento
R_p	Resistência paralela do módulo fotovoltaico
R_{pref}	Resistência paralela de referência
R_s	Resistência série do módulo fotovoltaico
R_{sref1}	Resistência série referente à irradiância
R_{sref2}	Resistência série referente à temperatura
R_{Sn}	Resistência elétrica do circuito de <i>snubber</i>
R_T	Resistência elétrica medida
R_0	Resistência elétrica à temperatura de 0 °C
Re	Revocação
S_a	Transistor para conexão da série fotovoltaica com a carga capacitiva
S_b	Transistor que controla a descarga do banco de capacitores
S_1	Transistor do módulo comutador - conexão com o inversor fotovoltaico
S_2	Transistor do módulo comutador - conexão com o traçador de curvas
s	Segundo
$serieFV$	Vetor com as séries fotovoltaicas em análise
T	Temperatura
T_a	Temperatura ambiente
T_C	Temperatura do encapsulamento
T_{car}	Período para carregar a carga capacitiva
T_{conv}	Temperatura de operação dos módulos fotovoltaicos convertida
T_D	Temperatura do dissipador
T_{des}	Período para descarregar a carga capacitiva
T_j	Temperatura na junção

T_{med}	Temperatura de operação dos módulos fotovoltaicos medida
T_{var}	Variação tolerável da temperatura
TB	Terabyte
US\$	Dólar
V	Volt
V	Tensão elétrica
V_{conv}	Tensão elétrica convertida
V_{med}	Tensão elétrica medida
V_{mp}	Tensão elétrica no ponto de máxima potência
$V_{mp_{med}}$	Tensão elétrica no ponto de máxima potência medida
$V_{mp_{mod}}$	Tensão elétrica no ponto de máxima potência modelada
$V_{mp_{norm}}$	Relação entre $V_{mp_{med}}$ e $V_{mp_{mod}}$
V_{oc}	Tensão elétrica de circuito aberto
$V_{oc_{med}}$	Tensão elétrica de circuito aberto medida
$V_{oc_{mod}}$	Tensão elétrica de circuito aberto modelada
$V_{oc_{ref}}$	Tensão elétrica de circuito aberto de referência
$V_{oc_{norm}}$	Relação entre $V_{oc_{med}}$ e $V_{oc_{mod}}$
V_T	Tensão térmica
VN	Verdadeiros negativos
VP	Verdadeiros positivos
W	Watt
W_n	Peso de um neurônio
X_n	Sinal de entrada de um neurônio
y	Saída de um neurônio
°C	Graus Celsius
α_i	Coefficiente de variação da corrente de curto-circuito com a temperatura (estimado pelo MGNL)
$\alpha_{I_{sc}}$	Coefficiente de temperatura da corrente de curto-circuito (catálogo)
β_S	Coefficiente de variação da tensão de circuito aberto com a irradiância (estimado pelo MGNL)
β_T	Coefficiente de variação da tensão de circuito aberto com a temperatura (estimado pelo MGNL)

$\beta_{V_{oc}}$	Coefficiente de temperatura da tensão de circuito aberto (catálogo)
γ_{mpp}	Coefficiente de temperatura da potência máxima
γ_{R_p}	Coefficiente exponencial da irradiância para resistência paralela
γ_{R_s}	Coefficiente exponencial da irradiância para resistência série
ΔG	Diferença entre a irradiância inicial e final
ΔT	Diferença entre a temperatura inicial e final
δ	Fator de correção da irradiância
ε	Constante que depende do material do módulo fotovoltaico
θ	Limiar de um neurônio
κ	Fator de correção da curva I-V
κ_{R_p}	Coefficiente linear de temperatura para resistência paralela
κ_{R_s}	Coefficiente linear de temperatura para resistência série
μ	Permeabilidade magnética relativa do material
μF	Microfarad
μH	Microhenry
ζ	Constante de interpolação
Ω	Ohm

SUMÁRIO

1	INTRODUÇÃO	21
1.1	FORMULAÇÃO DO PROBLEMA	22
1.1.1	Métodos para monitoramento e diagnóstico da geração fotovoltaica	23
1.2	OBJETIVOS	37
1.2.1	Objetivo geral	37
1.2.2	Objetivos específicos	37
1.3	MOTIVAÇÃO E JUSTIFICATIVA	38
1.4	CONTRIBUIÇÕES DO TRABALHO	45
1.5	DELIMITAÇÕES DO TRABALHO	46
1.6	ESTRUTURA DO TRABALHO	47
2	REFERENCIAL TEÓRICO	49
2.1	FATORES QUE IMPACTAM A GERAÇÃO FOTOVOLTAICA	49
2.1.1	Fatores construtivos e naturais que impactam a geração	51
2.1.2	Fatores operacionais que impactam a geração	53
2.2	MEDIÇÕES EM ARRANJOS FOTOVOLTAICOS	56
2.2.1	Medição de parâmetros elétricos	57
2.2.2	Medição da irradiância incidente sobre os módulos	57
2.2.3	Medição da temperatura de operação dos módulos	59
2.2.4	Amostragem e armazenamento dos dados	60
2.2.5	Impacto das incertezas das medições	61
2.3	AQUISIÇÃO DE CURVAS I-V EM ARRANJOS FOTOVOLTAICOS	61
2.3.1	Métodos para aquisição experimental da curva I-V	65
2.3.2	Soluções comerciais para aquisição de curvas I-V	69
2.3.3	Conversão da curva I-V para o STC	70
2.3.4	Análise da curva I-V	73
2.4	MODELAGEM DE ARRANJOS FOTOVOLTAICOS	76
2.4.1	Modelos baseados em inteligência artificial	77
<i>2.4.1.1</i>	<i>Uso da inteligência artificial na modelagem fotovoltaica</i>	<i>79</i>
2.4.2	Modelos baseados em circuitos elétricos	81
<i>2.4.2.1</i>	<i>Os principais modelos baseados em circuito elétrico</i>	<i>81</i>
<i>2.4.2.2</i>	<i>Outros circuitos elétricos empregados na modelagem fotovoltaica</i>	<i>84</i>
<i>2.4.2.3</i>	<i>Métodos para estimação dos parâmetros</i>	<i>85</i>
2.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	87
3	TRAÇADOR DE CURVAS I-V INTEGRADO À USINA	89
3.1	MÓDULO COMUTADOR	91

3.2	MÓDULO PARA AQUISIÇÃO DAS CURVAS I-V	98
3.2.1	Circuito de sensoriamento	99
3.2.2	Circuito operacional	101
3.2.3	Carga capacitiva	103
3.2.4	Circuito de processamento	104
3.2.5	Integração dos circuitos que compõem o módulo para aquisição das curvas I-V	107
3.3	MÓDULO PARA AQUISIÇÃO DOS PARÂMETROS CLIMÁTICOS	109
3.3.1	Medição da irradiância no plano inclinado	109
3.3.2	Medição da temperatura de operação dos módulos fotovoltaicos	111
3.3.3	Integração dos circuitos que compõem o módulo para aquisição dos parâmetros climáticos	113
3.4	MÓDULO CONTROLADOR	114
3.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	118
4	METODOLOGIA PARA O DIAGNÓSTICO DA GERAÇÃO DE USINAS FV	119
4.1	PRÉ-PROCESSAMENTO DE DADOS	122
4.2	DIAGNÓSTICO DE USINAS FOTOVOLTAICAS: ETAPA DE DETECÇÃO	125
4.2.1	O Modelo Global Não-Linear	126
4.3	DIAGNÓSTICO DE USINAS FOTOVOLTAICAS: ETAPA DE CLASSIFICAÇÃO	134
4.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	140
5	RESULTADOS	142
5.1	APRESENTAÇÃO DA USINA FOTOVOLTAICA	142
5.2	VALIDAÇÃO DO TRAÇADOR DE CURVAS I-V NA USINA	144
5.3	VALIDAÇÃO DA METODOLOGIA PARA DIAGNÓSTICO DA GERAÇÃO FV	148
5.3.1	Validação da etapa de detecção	148
5.3.2	Validação da etapa de classificação	158
5.4	CONSIDERAÇÕES FINAIS DO CAPÍTULO	162
6	CONCLUSÕES	163
6.1	TRABALHOS FUTUROS	166
6.2	PUBLICAÇÕES DO AUTOR ASSOCIADAS À TESE DE DOUTORADO	167
	REFERÊNCIAS	168

1 INTRODUÇÃO

Atualmente, o uso da eletricidade é uma necessidade básica no mundo, cujo consumo tem aumentado devido ao crescimento e ao desenvolvimento da população. Destaca-se que, as fontes renováveis estão cada vez mais presentes na matriz energética global, sendo a inclusão destas justificada pela necessidade de reduzir as emissões de dióxido de carbono e pelo aumento na eficiência das novas tecnologias (CALLEJO; SAAVEDRA; GÓMEZ, 2019).

Em 2019, estimou-se que para 2050, a energia elétrica se tornará a principal fonte de energia global, passando de uma participação de 20% no consumo final para uma participação de quase 50%. As fontes renováveis vão fornecer a maior parte dessa demanda de energia, sendo que cerca de 86% da energia elétrica gerada será renovável e 60% terá como origem as fontes solares e eólicas (IRENA, 2019).

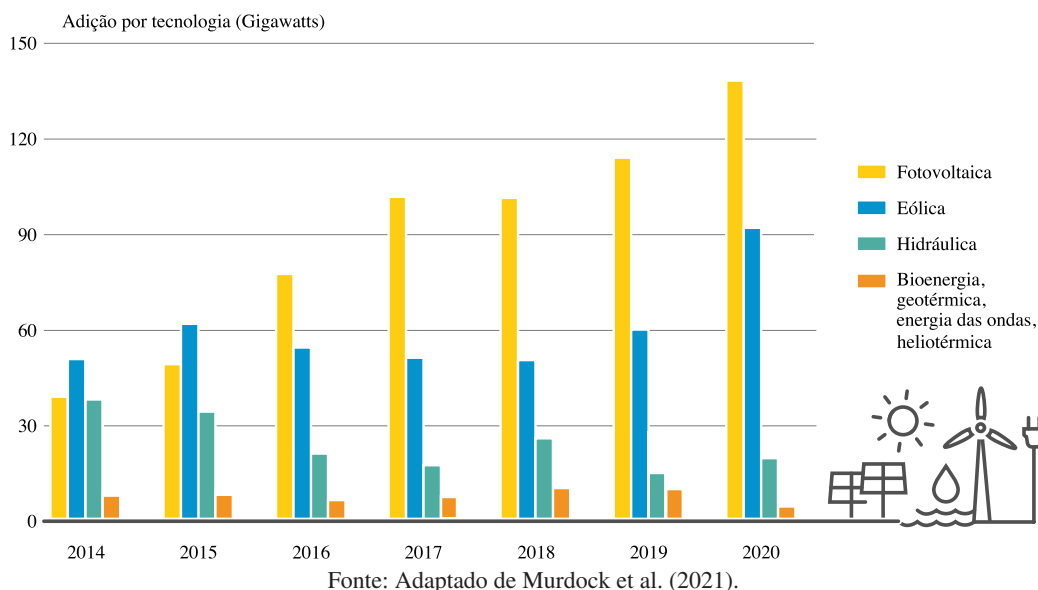
Em 2021, apesar da pandemia da COVID-19 e da guerra entre Ucrânia e Rússia que implicou em interrupções na cadeia de suprimentos, atrasos no envio e aumento dos preços dos componentes de energia eólica e solar, houve uma adição superior a 314 gigawatts (GW) na capacidade instalada das fontes renováveis ao redor do mundo, o que totalizou 3.146 GW. A China tornou-se o primeiro país a ultrapassar 1 terawatt (TW) de capacidade instalada, seguida pelos Estados Unidos (398 GW) e pelo Brasil (160 GW) (MURDOCK et al., 2022).

Em 2021, aproximadamente 28,3% da geração global de eletricidade foi fornecida por fontes renováveis, o que superou os níveis de 2011 (20,4%) e mostrou-se semelhante aos de 2020 (28,5%). Essa situação pode ser justificada, principalmente, pelas condições de seca que reduziram a geração hidrelétrica global nos últimos anos. As fontes hidrelétricas ainda predominam a geração renovável, embora as fontes solares e eólicas tenham apresentando um crescimento significativo nos últimos anos, conforme mostra a Figura 1. Em 2021, pela primeira vez, as fontes solares e eólicas foram responsáveis por mais de 10% da geração global de eletricidade (MURDOCK et al., 2022).

O mercado fotovoltaico (FV) global adicionou mais de 175 GW em sua capacidade instalada durante 2021, totalizando 942 GW. A China, líder do mercado, possui a capacidade instalada de 308,5 GW, seguida pela União Europeia (178,7 GW), pelos Estados Unidos (123 GW) e pelo Japão (78,2 GW). Na União Europeia, a Alemanha lidera com 59,2 GW, seguida pela Itália com 22,6 GW e pela Espanha com 18,5 GW (KAIZUKA et al., 2022).

As Américas representaram cerca de 21% do mercado fotovoltaico global em 2019, devido em grande parte aos Estados Unidos. Vários países da América Latina continuaram em expansão, apesar das condições econômicas desafiadoras em alguns países. O Brasil adicionou 5,5 GW e encerrou 2021 com quase 13 GW instalados, sendo o quinto país que mais agregou capacidade em fontes solares, um avanço em relação ao nono lugar ocupado em 2020 (MURDOCK et al., 2022).

Figura 1 – Adição anual global de fontes renováveis separadas por tecnologias.



1.1 FORMULAÇÃO DO PROBLEMA

Apesar da economia estar favorecendo o aumento dos sistemas distribuídos, os projetos em grande escala continuam dominando o mercado fotovoltaico global. Ao final de 2019, haviam, em operação, mais de 50 usinas fotovoltaicas com capacidade superior a 50 megawatts (MW) (MURDOCK et al., 2020). No entanto, além da construção de novas usinas, recentemente surgiram outras demandas para o setor fotovoltaico, sendo estas relacionadas com as atividades de Operação e Manutenção (O&M).

As atividades de O&M estão se tornando cada vez mais importantes para a viabilidade dos projetos fotovoltaicos. O processo de O&M é responsável por mitigar os riscos potenciais, melhorar a confiabilidade de longo prazo, o custo nivelado de energia, os preços dos contratos de compra e venda de energia, além de impactar positivamente no retorno sobre o investimento (LORENZO et al., 2020; MUÑOZ-CERÓN et al., 2018; CALLEJO; SAAVEDRA; GÓMEZ, 2019).

A O&M envolve um volume de negócios que dificilmente é mensurado em detalhes, isso ocorre devido à quantidade de fatores que impactam neste processo, como: o tamanho da matriz; o clima da região; as características do ambiente circundante; a distância da usina até um centro urbano; etc. Além disso, os custos de O&M mudam à medida que o sistema envelhece. O *Lawrence Berkeley National Laboratory* estimou o custo de O&M para usinas fotovoltaicas em cerca de US\$ 15,00/kW/ano (WALKER et al., 2020). O volume de negócios em nível global gira em torno de 7 bilhões de dólares, sendo este valor baseado em premissas conservadoras, onde desconsidera-se o custo do material substituído (MASSON; KAIZUKA et al., 2019).

No ciclo de vida de uma usina fotovoltaica, a fase de operação e manutenção pode perdurar por cerca de 20 até 35 anos. Trata-se da fase mais longa se comparado ao período

de projeto, construção, repotenciação e descomissionamento. Durante a fase de operação, os módulos fotovoltaicos ficam expostos ao ambiente externo e, apesar de não possuírem peças móveis, sofrem um processo de degradação. Além disso, estão suscetíveis a danos que podem ocorrer na fabricação, no transporte, na instalação e/ou durante a operação. Entre os fatores que degradam o desempenho das instalações fotovoltaicas, destacam-se: as falhas nos diodos de *by-pass*; a incompatibilidade dos módulos fotovoltaicos; a presença de pontos quentes; a ocorrência de arcos-elétricos; o sombreamento; a sujidade; etc.

A ocorrência desses fatores de degradação está condicionada diretamente com o local de instalação da matriz fotovoltaica. O trabalho proposto por Halwachs et al. (2019) classificou as causas da degradação de sistemas fotovoltaicos com base nas seguintes zonas climáticas: tropical (A), árido (B), temperado (C), neve (D) e polar (E). Os resultados mostraram que em todas as zonas climáticas foram identificadas falhas que causaram perdas na geração.

Halwachs et al. (2019) apontaram que algumas dessas falhas parecem ser intrínsecas a certas zonas climáticas, como os defeitos nos diodos de *by-pass* que ocorrem em módulos instalados na zona B e a sujidade por biofilme que está presente principalmente em módulos da zona A. Os autores também dissertam sobre os diversos tipos de sujeiras que podem atingir os módulos instalados nas zonas climáticas A e B. Sendo que, essa sujidade pode ocasionar sombreamentos parciais que podem implicar na ocorrência de falhas no encapsulante, na delaminação e na descoloração dos módulos fotovoltaicos. Além disso, destaca-se que, os módulos instalados nas zonas C e D podem ser afetados por tempestades de granizo. Já os módulos das zonas D e E estão suscetíveis ao estresse físico devido a sobrecargas de neve. Por fim, os autores concluem que existem muitas condições climáticas distintas e fatores de estresse ambiental que podem ser relevantes, o que torna difícil fornecer uma declaração universalmente válida para todas as zonas climáticas.

Ao considerar os custos, a longevidade da fase de O&M e os fatores de degradação, evidencia-se a importância dos métodos de monitoramento e avaliação de desempenho. No entanto, atualmente, a maioria dos sistemas comerciais para monitoramento fotovoltaico são apenas armazenadores de dados elétricos e climáticos, não sendo capazes de avaliar o desempenho da instalação fotovoltaica (CHIANTORE; PAPAECOMOMOU; DEGENER, 2018; OPREA et al., 2019).

1.1.1 Métodos para monitoramento e diagnóstico da geração fotovoltaica

Uma solução adequada para o monitoramento fotovoltaico deve possibilitar que o diagnóstico da geração seja eficaz, rápido e pouco oneroso. O monitoramento deve informar aos operadores sobre as condições atuais da geração e identificar os fatores de degradação do desempenho. Destaca-se que o conjunto de informações fornecido pelo sistema de monitoramento é essencial para as tomadas de decisões da equipe de O&M, o que maximiza a produção de energia e, conseqüentemente, potencializa a lucratividade da instalação fotovoltaica (CALLEJO; SAAVEDRA; GÓMEZ, 2019; CHIANTORE; PAPAECOMOMOU; DEGENER, 2018).

O mercado dispõe de um conjunto de soluções comerciais para o monitoramento fotovoltaico. Um levantamento realizado pela Revista FotoVolt (2020) apresentou as soluções comercializadas por 17 empresas do setor fotovoltaico, são elas:

ABB Eletrificação Monitoramento de inversores.

ABS Telemetria Comunicação com sensores, medidores de energia, inversores, controladores e outros.

Chint Monitoramento da potência, rendimento, eficiência, alarmes, falhas e outras informações.

Dualbase Tecnologia Monitoramento da radiação solar, temperatura, umidade, velocidade do vento e parâmetros elétricos da geração.

Elipse Software Monitoramento da radiação solar, potência, alarmes, controle dos inversores e da energia excedente no mês.

Engecomp Tecnologia Monitoramento dos equipamentos da usina, medição de faturamento e gestão de faturas. Além de um portal onde é possível verificar o consumo, a geração, as tensões e correntes mensuradas a cada minuto.

Engie Brasil Monitoramento da tensão, corrente, potência e energia.

Fronius do Brasil Monitoramento da potência, tensão e corrente. Sistema de monitoramento gratuito fornecido junto do inversor.

Gestal Monitoramento da energia gerada e consumida. Sistema de gerenciamento da energia elétrica.

IMS Monitoramento da energia, demanda e fator de potência.

Metrum Monitoramento da tensão, corrente, fator de potência, energia, distorções harmônicas, picos, afundamentos e distúrbios.

Novus Monitoramento de falhas, grandezas climáticas e elétricas.

Solarview AWC Tecnologia Monitoramento da energia gerada e consumida, ROI e eventos. Integra as informações de outros sistemas e possui análise de desempenho.

Spin Engenharia Monitoramento dos inversores, séries fotovoltaicas, estações solarimétricas e subestações.

Wago Brasil Monitoramento da potência, fator de potência, estado dos dispositivos de proteção e estações solarimétricas.

Way2 Tecnologia Monitoramento e gerenciamento dos créditos de energia.

WEG Geração de históricos sobre o desempenho dos geradores, análise da redução no impacto ambiental, gerenciamento remoto de falhas e alertas.

As soluções apresentadas, em sua grande maioria, realizam apenas a coleta e o armazenamento dos parâmetros elétricos e climáticos. São escassas as soluções que realizam o diagnóstico da instalação fotovoltaica e, quando realizado, ocorre através da comparação entre a energia gerada e a energia estimada para um dado período. Em geral, o mercado fotovoltaico dispõe de poucas soluções comerciais para o monitoramento, ainda mais quando busca-se por uma análise de desempenho. No entanto, a literatura científica apresenta uma série de ferramentas que se destacam nesse processo, são elas:

Uso de modelos fotovoltaicos os modelos são representações de sistemas reais que possuem o objetivo de estimar o seu comportamento em diversos pontos operacionais. Por exemplo, os modelos fotovoltaicos podem estimar a produção de energia para uma ampla gama de condições ambientais, de projeto e de local. Um sistema de monitoramento pode fazer o uso de um modelo para estimar a potência gerada e, através da comparação com a potência medida, avaliar o desempenho da instalação. Destaca-se que a comparação entre os parâmetros deve ocorrer com certa prudência, já que os modelos fazem o uso de premissas simplificadoras que resultam em um certo grau de incompatibilidade entre o comportamento operacional obtido pelo modelo e o real.

Um procedimento para medir a produção de energia de um sistema fotovoltaico e comparar com a produção estimada para esse mesmo sistema, a partir de condições climáticas reais, é definido pela especificação técnica IEC TS 61724-3. Esse procedimento permite identificar alguns problemas de desempenho, tais como: interrupções na geração ou períodos de baixo desempenho; procedimentos inadequados de manutenção; degradação da planta; etc. O desempenho da instalação é caracterizado pela quantificação da energia perdida nos períodos em que a planta não operou e por um indicador que quantifica o quão próximo está o desempenho em relação às expectativas. Para realizar este procedimento é necessário o uso de um modelo para o gerador fotovoltaico, ou seja, o módulo ou arranjo fotovoltaico. Contudo, a IEC não define a estrutura deste modelo, então cabe as partes envolvidas o acordo sobre qual estrutura será utilizada.

Na literatura são relatadas diversas técnicas que podem ser aplicadas na modelagem de arranjos fotovoltaicos, onde destacam-se os modelos baseados em inteligência artificial e os baseados em circuitos elétricos. Vale apontar que algumas soluções comerciais avaliam o desempenho de instalações fotovoltaicas através de modelos elétricos.

O sistema de monitoramento proposto por Davarifar et al. (2013) utiliza um modelo elétrico para estimar a potência do arranjo fotovoltaico. O resíduo entre a potência medida e a estimada é analisado pelo Teste de Wald, o qual permite verificar a evolução do resíduo no tempo e, conseqüentemente, avaliar o desempenho da instalação.

Existem sistemas de monitoramento que utilizam apenas alguns componentes do modelo elétrico. Por exemplo, o método proposto por Sera, Teodorescu e Rodriguez (2008) avalia o desempenho de uma matriz fotovoltaica através do valor da resistência série. Os autores propõem uma equação simplificada para determinar o valor desta resistência. A equação, apesar de não garantir o significado físico da resistência, é considerada adequada para o monitoramento.

Uma solução para estimar a corrente e a tensão de uma instalação fotovoltaica utilizando uma Rede Neural Artificial (RNA) foi proposta por Mekki, Mellit e Salhi (2016). A comparação entre os parâmetros estimados com os medidos permitiu avaliar o estado operacional da instalação. A RNA foi projetada com dois neurônios na camada de entrada que correspondem a irradiância e a temperatura, além de dois neurônios na camada de saída que correspondem a corrente e a tensão. A rede possui duas camadas ocultas, sendo a primeira com 7 neurônios e a segunda com 12. Logo, afirma-se que a RNA possui topologia 2-7-12-2. A rede foi treinada com o algoritmo *resilient-propagation*, conhecida como RPROP.

Técnicas de inteligência artificial o uso da inteligência artificial (IA) não limita-se à modelagem fotovoltaica. Alguns autores propõem o uso da IA em estratégias de avaliação de desempenho, onde não existe a necessidade de modelar o arranjo. Por exemplo, os autores Akram e Lotfifard (2015) empregaram uma rede neural de base radial para identificar e classificar as falhas de um sistema fotovoltaico em tempo real, especificamente as falhas de circuito aberto e de curto-circuito. A RNA possui quatro camadas, sendo a de entrada composta pela irradiação, temperatura, tensão e corrente no ponto de máxima potência, enquanto a camada de saída é dada pela classificação da falha.

Um outro exemplo do uso de uma RNA na classificação de falhas foi proposto Chine et al. (2016). Nesse caso, as ocorrências de baixo desempenho são identificadas através da comparação entre os parâmetros elétricos medidos com os parâmetros estimados por um modelo fotovoltaico. Para classificar o tipo da falha, os autores definiram um conjunto de assinaturas, por exemplo: redução da corrente e tensão constante. No entanto, existem algumas falhas que possuem a mesma assinatura e, neste caso, uma RNA é empregada na distinção dessas falhas. A RNA possui três neurônios na camada de entrada, correspondentes a razão entre os parâmetros medidos e simulados da tensão de circuito aberto, da corrente no ponto de máxima potência e da tensão no ponto de máxima potência. Um neurônio na camada de saída corresponde à classificação da falha. A topologia da RNA é 3-13-13-1 e foi treinada com o algoritmo *Levenberg-Marquardt*.

O diagnóstico de pontos quentes em arranjos fotovoltaicos foi investigado por Dhimish (2021). Os autores realizaram uma comparação entre quatro classificadores de aprendizado de máquina: árvore de decisão, máquina de vetor de suporte, algoritmo *k-Nearest Neighbor* e classificadores discriminantes lineares e quadráticos. Os resultados mostraram que os

classificadores discriminantes alcançaram a maior precisão de detecção (98%), enquanto que as árvores de decisão tiveram o pior desempenho (84%).

Um método baseado em algoritmos de aprendizado profundo foi proposto por Mustafa et al. (2023) para detectar, classificar e localizar as situações de curto-circuito e circuito aberto nas séries fotovoltaicas. O método destaca-se pela redução do quantitativo de sensores necessários para essa análise se comparado com as abordagens clássicas da literatura. De acordo com os autores, a classificação e a localização das falhas são obtidas com precisão de 99,94% e 99,54%, respectivamente.

As situações de baixo desempenho que estão relacionadas com a má conexão física entre os módulos ou entre as células fotovoltaicas, assim como a quebra do vidro frontal de módulos e a presença de diodos de *by-pass* danificados são investigadas por Wang, Lin e Lu (2022). Os autores utilizam um algoritmo denominado de padrão de pontos simétricos que transforma os sinais elétricos mensurados em gráficos visuais. Uma rede neural convolucional utiliza essas imagens no reconhecimento das falhas. De acordo com os autores, o algoritmo possui a precisão de 99,88% para o reconhecimento dessas falhas.

Uma metodologia para diagnosticar falhas de curto-circuito em uma mesma série fotovoltaica ou entre séries distintas, assim como falhas de circuito aberto foi proposta por Lu et al. (2023). Nesse caso, os autores propõem uma metodologia de detecção e diagnóstico de falhas que utiliza um conjunto de dados rotulados, o algoritmo GAN de Wasserstein (uma variação de redes adversárias generativas) e uma rede neural convolucional. O método se destaca por utilizar um pequeno conjunto de dados rotulados para gerar um conjunto maior que é empregado no treinamento do classificador. A metodologia foi aplicada em um sistema fotovoltaico real e apresentou bons resultados de classificação.

Os autores Mellit et al. (2023) propuseram um sistema embarcado para monitoramento remoto e diagnóstico de falhas de sistemas fotovoltaicas. Uma rede neural artificial é utilizada para identificar os períodos de baixo desempenho e o algoritmo de aprendizado de máquina *Stacking Ensemble* realiza a classificação da falha. Uma rede neural artificial do tipo *perceptron* multicamadas foi treinada para modelar o arranjo fotovoltaico. A comparação entre a potência medida e a potência estimada permite identificar os períodos de baixo desempenho do arranjo. O algoritmo de aprendizado de máquina, responsável por classificar as falhas, permite identificar as seguintes situações: i) sujidade, ii) sombreamento parcial, iii) diodo de *by-pass* em circuito aberto e sujidade, iv) sombreamento parcial e sujidade e v) diodo de *by-pass* em condução e sombreamento. Os resultados mostram que a detecção dos períodos de baixa geração alcançou a precisão de 97,5%, enquanto a classificação das falhas alcançou 96,8%.

As técnicas de inteligência artificial estão sendo amplamente utilizadas no diagnóstico de instalações fotovoltaicas, em especial, as redes neurais artificiais. Uma revisão bibliográfica proposta por Yuan, Xiong e Fu (2022) permite identificar os modelos de RNAs que estão

sendo mais utilizados, os atributos de entradas desses modelos, os tipos de falhas que podem ser reconhecidas e o desempenho dessas redes. O trabalho pode ser considerado como um guia para o uso de RNAs no diagnóstico de instalações fotovoltaicas.

Análise de curvas I-V a análise da curva característica, denominada de curva I-V (corrente-tensão), permite obter informações valiosas na detecção de falhas e no cálculo quantitativo das perdas de energia. A análise da curva I-V pode auxiliar em tarefas como: estimar a taxa de degradação ao longo do tempo, detectar as falhas no arranjo fotovoltaico, analisar os efeitos de sombreamento e as perdas por incompatibilidade dos módulos, avaliar a geração e o desempenho da matriz fotovoltaica, etc. Em resumo, a curva I-V pode ser considerada como um certificado de qualidade do arranjo fotovoltaico e se trata da medição de desempenho mais completa para os módulos fotovoltaicos. Destaca-se que, a curva I-V é independente do inversor, o que possibilita, no comissionamento de uma usina, testar toda a matriz antes do inversor ser colocado em operação (CUNNINGHAM; HERNDAY; MOKRI, 2014).

Avaliar o desempenho de uma matriz fotovoltaica através da análise da curva I-V é um método consolidado e relatado por muitos autores. Por exemplo, Hirata et al. (2012) propõem um sistema de monitoramento que avalia o desempenho da matriz através da comparação entre as curvas I-V adquiridas para cada série FV. No caso de operação normal, a diferença entre as curvas deve ser inferior a 5%, caso contrário, um alarme é emitido.

Uma abordagem semelhante a anterior foi proposta por Spataru et al. (2015). Os autores propõem a comparação das curvas I-V de séries fotovoltaicas idênticas. No entanto, este método diferencia-se em relação ao anterior no modo de classificação das falhas, a qual ocorre através da análise das seguintes proporções: P_{mp1}/P_{mp2} , I_{mp1}/I_{mp2} , V_{mp1}/V_{mp2} , V_{oc1}/V_{oc2} , V_{mp}/V_{oc} e I_{mp}/I_{sc} .

A comparação entre uma curva I-V medida no arranjo fotovoltaico com a curva I-V estimada por um modelo fotovoltaico foi a metodologia utilizada por Ali et al. (2017). O método realiza a análise de seis pontos de interesse da curva I-V e, de acordo com as deformações percebidas, classifica a falha identificada.

Um método para reconhecer padrões na curva I-V foi proposto por Huang, Wai e Yang (2019). Através de um algoritmo do tipo Colônia de Abelhas e de uma Máquina de Aprendizado Extremo, o método possui o objetivo de avaliar o desempenho da matriz fotovoltaica e identificar situações do tipo: curto-circuito; sombreamento parcial; envelhecimento anômalo e sujidade. Os resultados mostraram que o método alcançou uma boa precisão para a classificação das falhas.

Uma investigação entre seis técnicas de aprendizado de máquina com o objetivo de classificar sete condições de falhas em instalações fotovoltaicas foi realizada por Li et al. (2021). Entre as técnicas analisadas estão: rede neural artificial, máquina de vetor de

suporte, árvore de decisão, floresta aleatória, algoritmo *k-Nearest Neighbor* e classificador bayesiano. As falhas foram classificadas através do processamento de curvas I-V e ocorreu com dados simulados e dados reais obtidos em uma matriz fotovoltaica composta por 6 módulos fotovoltaicos. As curvas foram adquiridas através do traçador de curvas I-V comercial FTV200, fabricado pela Chauvin-Arnoux. De acordo com os autores, as redes neurais artificiais apresentaram os melhores resultados e atingiram 100% de precisão de classificação.

Uma comparação entre um sistema de monitoramento fotovoltaico típico com um traçador de curvas I-V comercial foi realizada pelos autores Jones et al. (2018). O sistema convencional, denominado SMA *Cluster Controller* é capaz de monitorar e armazenar a cada 5 minutos a corrente, a tensão e a potência. O traçador de curvas I-V, modelo Pordis 140A, foi configurado para adquirir as curvas a cada 30 minutos. Os resultados mostram que o sistema SMA apresentou os melhores resultados para a quantificação da energia gerada. Por outro lado, uma situação de sombreamento parcial só pode ser detectada através da análise da curva I-V.

Termografia trata-se de uma tecnologia que está se consolidando na análise de desempenho de plantas fotovoltaicas. A radiação térmica, invisível ao olho humano, pode ser medida por meio de uma câmera infravermelha e apresenta, como resultado uma imagem térmica, a qual permite identificar gradientes de temperatura. Geralmente, ao surgirem anomalias nos módulos fotovoltaicos, ocorre um aumento da resistência interna do módulo e, conseqüentemente, leva a uma mudança na temperatura de operação. Logo, ao analisar a imagem térmica, é possível avaliar o desempenho dos módulos fotovoltaicos (CALLEJO; SAAVEDRA; GÓMEZ, 2019).

A inspeção termográfica é considerada como um ensaio opcional pela Norma IEC 62446-1, a qual é responsável por regulamentar os testes de comissionamento e inspeção de sistemas fotovoltaicos conectados à rede. As imagens termográficas fornecem indicações claras e concisas sobre o estado dos módulos, mas também possibilitam avaliar problemas em outros componentes do sistema, como: diodos, cabos, conectores, fusíveis, interruptores, inversores, baterias, etc. (CHIANTORE; PAPAECONOMOU; DEGENER, 2018).

Destaca-se que o ensaio termográfico possui uma série de pré-requisitos, como: irradiância igual ou superior a 600 W/m^2 , resolução da câmera infravermelha de pelo menos 320×240 pixels, sensibilidade térmica de pelo menos $0,1 \text{ K}$, entre outras premissas que podem ser encontrados na IEC TS 62.446-3.

A inspeção termográfica pode ser dividida em dois momentos: a aquisição da imagem térmica e o processamento das imagens. Nesse sentido, os autores Vergura, Marino e Carpentieri (2015) desenvolveram um fluxo de trabalho para realizar o processamento das imagens térmicas e através desta análise extrair informações qualitativas e quantitativas sobre o estado operacional de cada célula fotovoltaica de um módulo.

A análise termográfica e o rastreamento da curva I-V podem ser bons companheiros na análise de um sistema fotovoltaico. Um módulo que possui anomalias térmicas pode ter a sua curva I-V rastreada para quantificar o impacto no seu desempenho. Por outro lado, a análise termográfica pode ser útil na localização dos módulos defeituosos (CUNNINGHAM; HERNDAY; MOKRI, 2014).

O ensaio termográfico em uma planta fotovoltaica exige tempo e trabalho. Consequentemente, nos últimos anos tem-se aperfeiçoado o uso de veículos aéreos não tripulados (VANTs) no monitoramento fotovoltaico, principalmente em usinas de grande porte e que frequentemente estão localizadas em áreas remotas.

Grimaccia et al. (2017) analisaram as principais falhas que podem ser identificadas em uma matriz fotovoltaica ao utilizar um VANT. Os autores propõem um software para selecionar automaticamente as imagens térmicas que potencialmente apresentam módulos defeituosos. Por sua vez, as imagens selecionadas são comparadas com imagens fotográficas correspondentes e auxiliam o operador na identificação e classificação das falhas.

O uso de algoritmos de visão computacional com técnicas de posicionamento de alta precisão para identificação de anomalias em instalações fotovoltaicas foi proposta por Addabbo et al. (2017) e Addabbo et al. (2018). Um VANT sobrevoa uma matriz FV e coleta imagens térmicas dos módulos, estas imagens são processadas através de um algoritmo de visão computacional executado a bordo do próprio veículo. O posicionamento fornecido pelo sistema de georreferenciamento permite identificar a localização exata do módulo defeituoso. As informações processadas são enviadas automaticamente ao setor de O&M da usina fotovoltaica.

Os autores Li et al. (2019) propuseram um algoritmo que utiliza apenas imagens fotográficas processadas por uma rede neural convolucional para detectar e classificar os módulos fotovoltaicos defeituosos. Com base nos resultados, um sistema de decisão sugere algumas ações para a equipe de O&M, tais como: limpar a poeira acumulada ou substituir os módulos quebrados.

Um método para classificar, a partir de imagens termográficas, os diferentes tipos de fatores de degradação que podem atingir os módulos fotovoltaicos foi proposto por Korkmaz e Acikgoz (2022). As imagens foram coletadas com VANTs equipados com câmeras infravermelhas de onda média e onda longa. O método utiliza uma rede neural convolucional para classificar 11 fatores de degradação, como rachaduras, diodos de *by-pass* defeituosos, pontos quentes, módulos fotovoltaicos desenergizados, etc. Os autores alcançaram a precisão de 97,32% para detecção de falhas e 93,51% para identificação dos fatores de degradação.

Eletroluminescência a imagem por eletroluminescência (EL), apesar de muitos confundirem, difere da imagem térmica e se trata de uma outra tecnologia para o monitoramento

e avaliação de desempenho de módulos fotovoltaicos. A eletroluminescência permite a identificação detalhada de falhas invisíveis ao olho humano e que geralmente não são conclusivas através do ensaio termográfico (CHIANTORE; PAPAECONOMOU; DEGENER, 2018).

O ensaio de eletroluminescência consiste na detecção da radiação infravermelha próxima (NIR), ou seja, comprimentos de onda entre 0,75 a 1,4 μm , isso é obtido ao conectar uma fonte de alimentação em c.c. ao módulo fotovoltaico. A detecção das emissões de NIR é realizada por uma câmera fotográfica e o ensaio geralmente ocorre em ambientes escuros, pois o sinal de luminescência do silício cristalino é inferior ao da luz solar (CUNNINGHAM; HERNDAY; MOKRI, 2014).

Um ensaio de eletroluminescência para avaliar as perdas causadas pela degradação induzida por potencial (PID) em módulos fotovoltaicos foi realizado por Bedrich et al. (2018). O cálculo das perdas utilizou imagens do ensaio de EL, a corrente média aplicada durante o ensaio e a corrente de curto-circuito do módulo. Os autores propuseram um modelo para estimar as perdas por PID.

A restrição que impõem a realização dos ensaios de eletroluminescência em ambientes escuros, preferencialmente a noite, foi resolvida por Benatto et al. (2020). Os autores propuseram um método de pós-processamento das imagens de EL que permite adquiri-las ao longo do dia e em alta velocidade. Inclusive, o método possibilitou o uso de drones na aquisição das imagens de EL. Apesar destas imagens ainda possuírem qualidade inferior se comparadas com as imagens capturadas em ambientes escuros, elas trazem informações que viabilizam o diagnóstico e a identificação de falhas.

Fluorescência UV trata-se de um método ainda incipiente para avaliação de desempenho de módulos fotovoltaicos, mas com grande capacidade de crescimento. O método destaca-se na detecção de fissuras e de pontos quentes. O ensaio é realizado ao irradiar os módulos com uma fonte de luz ultravioleta (UV) e observar o efeito da fluorescência a olho nu ou com uma câmera fotográfica. A extinção da fluorescência em torno das fissuras permite a interpretação de uma linha do tempo, as fissuras com fluorescência mais fracas são mais recentes do que aquelas que apresentam extinção total. O ensaio pode ser realizado durante o dia, sem a necessidade de eletrificação dos módulos, o que permite considerá-lo como uma alternativa mais rápida do que o método de eletroluminescência (HERRMANN et al., 2021a; MORLIER et al., 2018).

O ensaio de fluorescência UV é diretamente influenciado pela temperatura. De acordo com Morlier et al. (2018), a intensidade da fluorescência diminui com o aumento da temperatura do módulo e da fonte de luz UV. A fluorescência de um módulo fotovoltaico a uma temperatura operacional de 55 °C apresenta uma redução em comparação com a mesma situação à 25 °C de 3% à 30%. Essa situação pode levar à extinção da fluorescência

em áreas fracamente fluorescentes e, portanto, pode ocorrer a perda de informações essenciais para a análise do histórico de fissuras do módulo.

Uma metodologia para aperfeiçoar o ensaio de fluorescência UV e que possibilitou a inspeção de mais de 1.000 módulos fotovoltaicos por hora foi proposta por Gilleland, Hobbs e Richardson (2019). A metodologia consiste em um operador que caminha ao lado dos módulos fotovoltaicos segurando um sistema composto por uma fonte de luz UV de alta intensidade e uma câmera fotográfica. Um software de código aberto, denominado OpenUFV, foi proposto pelos autores para o processamento automático destas imagens. O software foi projetado para ensaios noturnos, pois as imagens à luz do dia não possuem a mesma qualidade para identificação de falhas. Os autores validaram os resultados em 11 plantas fotovoltaicas e alcançaram uma precisão superior a 90% na detecção de fissuras.

Espectroscopia trata-se de uma técnica utilizada em diversos dispositivos elétricos, inclusive em módulos fotovoltaicos, para obter informações sobre as condições operacionais destes equipamentos. Para realizar o ensaio, o dispositivo é conectado a uma fonte de alimentação e, então, mede-se a resposta em frequência deste dispositivo para perturbações senoidais em diferentes faixas de frequência. Ao analisar a resposta é possível obter um diagnóstico sobre o funcionamento do dispositivo. Por exemplo, no caso de módulos fotovoltaicos é possível identificar os níveis de degradação por PID (HERRMANN et al., 2021a).

Um estudo que investigou o uso da espectroscopia para identificar módulos fotovoltaicos degradados por PID foi desenvolvido por Oprea et al. (2016). Em um primeiro momento, os autores realizaram ensaios de eletroluminescência e análise da curva I-V para identificar os módulos que estavam degradados por PID. Posteriormente, estes módulos foram submetidos ao ensaio de espectroscopia, onde identificou-se a redução da resistência paralela e o aumento da capacitância dos módulos, o que confirmou a degradação por PID e a eficácia do ensaio de espectroscopia.

Em geral, para que o ensaio de espectroscopia possa ser realizado é necessário desconectar o módulo fotovoltaico da matriz. No entanto, uma solução que automatiza este ensaio foi proposta por Shelembe e Barendse (2020). Os autores projetaram um conversor para sistemas fotovoltaicos não conectados à rede que executa o ensaio de espectroscopia e fornece resultados satisfatórios quando comparado a um Analisador de Resposta de Frequência. O conversor proposto realiza tanto o controle de carga da bateria, como realiza automaticamente o ensaio de espectroscopia dos módulos, o que permite monitorar a degradação da matriz.

As ferramentas supracitadas estão consolidadas pela literatura científica e são frequentemente revisadas por novos trabalhos que abordam o diagnóstico de instalações fotovoltaicas. No entanto, ainda existem algumas metodologias que merecem destaque, são elas:

Comunicação via rede elétrica a tecnologia de transmissão de dados que utiliza a rede elétrica como meio físico (PLC, do inglês *Power Line Communication*) foi adotada no sistema de monitoramento proposto por Mao et al. (2017). Os autores desenvolveram um sistema de monitoramento a nível de módulo que utiliza o próprio barramento c.c. da matriz fotovoltaica para a transmissão dos parâmetros elétricos e climáticos mensurados até uma unidade central. O sistema realiza a medição da tensão, da corrente e da temperatura de cada módulo FV. A principal vantagem do monitoramento a nível de módulo está na capacidade de identificar a posição exata dos módulos que apresentam baixo desempenho e, conseqüentemente, corrigir rapidamente a falha.

O monitoramento a nível de módulo precisa ser de baixo custo para viabilizar a sua instalação em matrizes de grande porte. Os autores Han et al. (2017) propuseram um sistema de monitoramento que também faz uso da tecnologia PLC. Neste caso, o trabalho diferencia-se em relação ao anterior devido ao agrupamento dos módulos fotovoltaicos. Cada dispositivo PLC monitora simultaneamente quatro módulos FV e realiza a medição da tensão e da corrente de cada módulo FV. O agrupamento dos módulos permite reduzir o número de dispositivos PLC e contribui na redução do custo total do sistema de monitoramento. A detecção das falhas é realizada por uma unidade central e ocorre através da comparação e contraste dos parâmetros mensurados entre os diferentes agrupamentos.

Métodos estatísticos as metodologias que fazem uso de métodos estatísticos para avaliar o desempenho de instalações fotovoltaicas estão se destacando nos últimos anos. Por exemplo, na proposta dos autores Garoudja et al. (2017) foi utilizado um modelo FV elétrico e o gráfico da média móvel exponencial (MME) para identificar o baixo desempenho da instalação. A detecção ocorreu através da análise dos resíduos entre a potência estimada e a medida. O método proposto é capaz de classificar o agente de degradação em: curto-circuito, circuito aberto e sombreamento. O uso da MME possibilita identificar pequenas mudanças no valor médio, pois as medições mais recentes são mais influentes que as medições precedentes, embora não se descarte completamente as observações anteriores. Uma vantagem dessa técnica está na sua facilidade de implementação em tempo real devido ao seu baixo custo computacional.

Uma evolução do trabalho anterior foi proposta por Harrou, Taghezouit e Sun (2019). Neste caso, foram aplicadas as transformadas Wavelets (TW), uma técnica que permite reduzir o ruído dos sensores nas medições elétricas e, conseqüentemente, eliminar os alarmes falsos. Os autores mostram que dados contaminados com uma grande quantidade de ruído podem resultar na perda de características importantes e mascarar falhas potenciais. Os resultados mostraram que o uso da MME com as TW melhorou significativamente a qualidade e a robustez do monitoramento.

O uso de métodos estatísticos com o objetivo de aperfeiçoar as atividades de O&M foi proposto por Oprea et al. (2019). Os autores utilizaram um modelo probabilístico com

base em cadeias de Markov para calcular os indicadores de confiabilidade para o tempo médio entre falhas e o tempo médio até a falha. Além disso, foi proposto um algoritmo para estimar o número de possíveis paradas técnicas de uma usina fotovoltaica.

Soluções de baixo custo a Internet das Coisas (IoT, do inglês *Internet of Things*) está possibilitando a interação do usuário com a maioria dos objetos do nosso dia-a-dia, por exemplo: eletrodomésticos, eletroeletrônicos, veículos, etc. Nos últimos anos, devido a expansão da IoT, estão sendo reduzidos os custos dos dispositivos que fazem parte desse portfólio (microcontroladores, atuadores e sensores). Esses dispositivos estão sendo aderidos pelos sistemas de monitoramento fotovoltaico e dando origem as soluções de baixo custo. Inclusive, já considera-se que a IoT possibilitou a aquisição de um grande volume de dados e permitiu que essas informações sejam empregadas nas avaliações de desempenho, nas estimativas de geração e lucratividade dos projetos (KUMAR; ATLURI; PALAPARTHI, 2018).

Os autores Silvestre et al. (2014) propuseram um método que necessita de poucos sensores e baixa capacidade de processamento. O uso de sensores limita-se as medições climáticas (irradiância e temperatura), enquanto que os parâmetros elétricos são obtidos diretamente do inversor fotovoltaico. A avaliação de desempenho ocorre através do cálculo de dois indicadores, um para corrente e outro para tensão, ambos propostos pelos autores.

Na mesma linha de pesquisa, Kohno et al. (2019) propôs um método que não requer a instalação de nenhum sensor. Tanto a irradiância como a temperatura dos módulos fotovoltaicos são estimadas a partir dos valores de corrente e tensão que são medidos pelo inversor. O método de avaliação de desempenho compara o ponto operacional do inversor com o ponto operacional estimado por um modelo fotovoltaico. Dessa forma, o método proposto permite identificar situações de aumento da resistência série, redução da resistência paralela e falha nos diodos de *by-pass*.

Pereira et al. (2018) implementou um sistema de monitoramento de baixo custo para aquisição e transmissão de dados através de uma plataforma Raspberry Pi. O sistema realiza o monitoramento da tensão, da corrente, da irradiância, da umidade relativa, da temperatura ambiente e da temperatura dos módulos fotovoltaicos. Os dados são armazenados em um banco de dados online e podem ser acessados por meio de uma plataforma Web desenvolvida pelos próprios autores.

Um sistema de monitoramento modular foi proposto pelos autores Pereira, Jucá e Carvalho (2019). A solução emprega um servidor na nuvem para o armazenamento dos dados e possui o objetivo de tornar-se uma solução para interligar uma rede mundial de monitoramento. Atualmente, a solução está instalada em três usinas, sendo duas no Brasil e outra na Alemanha, sendo capaz de monitorar os dados climáticos do ambiente circundante e a temperatura de operação dos módulos fotovoltaicos.

Uma proposta de baixo custo para monitoramento fotovoltaico a nível de módulo foi apresentada por Andò et al. (2015). Nesse caso, os autores utilizaram sensores sem fio de baixo custo para medir a tensão, a corrente, a irradiância e a inclinação de cada módulo fotovoltaico. Os dados adquiridos são transferidos para uma central responsável pela avaliação de desempenho. O diagnóstico é realizado através da comparação entre a eficiência medida em cada módulo e a eficiência esperada.

Uma outra solução IoT de baixo custo para coletar e monitorar em tempo real os parâmetros climáticos e elétricos de uma instalação fotovoltaica foi proposta por Cheddadi et al. (2020). Para tornar a solução de baixo custo, os autores optaram pelo uso de softwares livres e pela escolha de microcontroladores e sensores de baixo custo. Os dados mensurados são armazenados em um banco de dados InfluxDB, uma plataforma de código aberto desenvolvida para lidar com alto volume de consultas e escritas. As informações registradas podem ser acessadas através do Grafana, uma plataforma de código aberto para monitoramento, análise e visualização de dados.

Indicadores de desempenho os indicadores de desempenho fornecem uma visão sobre o desempenho da usina em questão. Geralmente, esses indicadores não são empregados diretamente no monitoramento, mas como uma métrica para quantificar a qualidade dos processos de O&M. Por exemplo, os indicadores mostram se a manutenção preditiva está sendo bem executada, a manutenção corretiva é rápida e eficaz, a operação está ocorrendo dentro dos limites estabelecidos, etc. Entre os indicadores, destaca-se a taxa de desempenho (*PR*), cuja principal vantagem está em não necessitar de um modelo fotovoltaico. A *PR* leva em consideração apenas a irradiância medida no plano e a energia gerada, o que a torna um indicador aceito globalmente e frequentemente utilizado no monitoramento fotovoltaico (KHALID et al., 2016).

A literatura apresenta alguns estudos que mostram a eficácia dos indicadores de desempenho no monitoramento de usinas. Por exemplo, uma usina de 3 MW teve o seu desempenho verificado por Padmavathi e Daniel (2013) através dos seguintes indicadores: rendimento de referência, rendimento específico, perdas e eficiência do sistema. Em um outro caso, uma instalação de 11,2 kW foi investigada por Sharma e Goel (2017) através da eficiência dos módulos e do inversor, da taxa de desempenho, do rendimento da matriz e do rendimento final. Sharma e Chandel (2013) avaliaram uma usina de 190 kW pelo rendimento de referência, rendimento final, taxa de desempenho, fator de capacidade e eficiência do sistema. O comissionamento de uma usina de 20 MW foi relatado por Kwofie, Mensah e Antwi (2019), os autores levaram em consideração o perfil de demanda, o fator de potência e a distorção harmônica da corrente e da tensão no ponto de acoplamento.

Os indicadores de desempenho podem ser calculados em diferentes períodos de tempo, mas geralmente são calculados anualmente. Sugere-se o período anual para evitar que pequenas flutuações na irradiação solar ou na geração de energia interfiram no valor dos

indicadores. Ao utilizar um longo período, as pequenas flutuações não causam um grande impacto no valor médio das grandezas utilizadas nos cálculos dos indicadores. Geralmente, devido a esse longo período que os indicadores não são utilizados no monitoramento de usinas. Afinal, as falhas seriam identificadas somente após o cálculo de um indicador que poderia ocorrer meses após o surgimento da falha (CHIANTORE; PAPAECONOMOU; DEGENER, 2018; HANSEN; STEIN; LUKETA-HANLIN, 2013).

Monitoramento no lado c.a. os sistemas de monitoramento, em geral, analisam o desempenho apenas no lado c.c. do sistema fotovoltaico. Contudo, na literatura estão disponíveis alguns trabalhos que abordam o monitoramento no lado c.a., o que permite identificar as falhas do inversor fotovoltaico. Por exemplo, os autores Platon et al. (2015) propuseram um modelo para estimar a energia gerada no lado c.a. da planta. O modelo de baixa complexidade possui como entrada a irradiância solar e a temperatura de operação dos módulos. A avaliação de desempenho é baseada na comparação entre a energia c.a. medida com a energia estimada pelo modelo.

Uma outra maneira de monitorar o lado c.a. foi proposta por Xia et al. (2020). Neste caso, o sistema de monitoramento é composto apenas por sensores de corrente e tensão. Os dados aferidos são enviados a um dispositivo coordenador, o qual é responsável por receber as informações e transferi-las para a nuvem. Por fim, um algoritmo que faz uso das transformadas Wavelet e com base nas distorções dos parâmetros mensurados é capaz de diagnosticar o baixo desempenho da planta.

Vale destacar que ainda existem muitas outras técnicas que podem ser aplicadas no monitoramento fotovoltaico, mas que não possuem uma categoria específica para classificação. Por exemplo, os autores Hariharan et al. (2016) propuseram um método que permite classificar três possíveis cenários: operação normal; sombreamento parcial e falha. A distinção entre os cenários ocorre devido a dinâmica de um parâmetro de referência que foi proposto pelos próprios autores, sendo esse parâmetro dado pela razão entre a potência da matriz fotovoltaica pela irradiação solar. Neste caso, para as situações de sombreamento parcial, o parâmetro de referência varia gradualmente, enquanto que para situações de falhas a variação é abrupta.

Ao analisar as ferramentas e metodologias que estão disponíveis na literatura para o monitoramento e diagnóstico de instalações fotovoltaicas é possível concluir que, apesar das inúmeras soluções, até o momento não existe uma solução ótima que possibilite aos operadores identificar todos os fatores de degradação da matriz. Geralmente, recomenda-se o uso de uma combinação de soluções em conjunto, essa foi a técnica adotada pelos autores Ali et al. (2018) que analisaram o desempenho de módulos fotovoltaicos através dos métodos de termografia, eletroluminescência e fluorescência UV. O ensaio de termografia permitiu a identificação de pontos quentes, a eletroluminescência mostrou os módulos que sofreram as maiores taxas de degradação e o ensaio de fluorescência UV auxiliou no diagnóstico de fissuras e na identificação de pontos de descoloração dos módulos.

Apesar de cada uma das soluções apresentadas possuírem pontos positivos e negativos, a análise da curva I-V mostrou-se um dos métodos mais completos e que possibilita aos operadores a identificação de uma série de fatores de degradação. Inclusive, o mercado fotovoltaico já dispõe de equipamentos comerciais para o rastreio de curvas I-V de séries fotovoltaicas. No entanto, esses equipamentos geralmente operam de forma manual e, conseqüentemente, a aquisição das curvas de uma matriz fotovoltaica implica em um longo período de trabalho - o operador deve desconectar manualmente do inversor cada uma das séries fotovoltaicas que compõem a matriz, conectá-las no traçador de curvas e depois reconectá-las na matriz. Além disso, esse tipo de tarefa acaba expondo o operador a riscos letais de choque elétrico.

Logo, diante da necessidade de soluções computacionais “mais inteligentes” para avaliar o desempenho de usinas e diante das vantagens que a análise da curva I-V agrega nesse processo, elaborou-se o seguinte tema de pesquisa: Desenvolver uma solução automática para avaliar o desempenho de usinas fotovoltaicas e que seja capaz de identificar os principais fatores de degradação de desempenho através da análise de curvas I-V.

1.2 OBJETIVOS

A fim de encontrar a resposta para a pergunta, são apresentados, a seguir, o objetivo geral e os objetivos específicos deste trabalho.

1.2.1 Objetivo geral

Propor uma metodologia que possibilite a contínua avaliação de desempenho no lado c.c. de usinas fotovoltaicas com base na medição automatizada das curvas I-V de séries FV e na utilização de tais curvas em algoritmos desenvolvidos com a finalidade de detectar e categorizar falhas e modos de degradação.

1.2.2 Objetivos específicos

- Desenvolver o hardware de um traçador de curvas I-V automático para ser integrado à caixa de junção de usinas, que viabilize a medição automática da curva I-V de cada série do arranjo fotovoltaico e que permita o acesso remoto às curvas mensuradas. Projetar o hardware em conformidade com os requisitos técnicos descritos na normatização vigente;
- Propor uma metodologia para avaliação de desempenho de usinas fotovoltaicas que viabilize o diagnóstico automático, identifique os fatores de degradação e classifique a condição operacional de cada série do arranjo fotovoltaico. Viabilizar o acesso remoto a condição operacional das séries FV.

1.3 MOTIVAÇÃO E JUSTIFICATIVA

O crescimento exponencial das tecnologias fotovoltaicas abre caminho para um mundo movido a energia solar, mas que ainda necessita de progressos para torna-se uma fonte de baixo custo e de alta confiabilidade. Em geral, pode-se definir a confiabilidade de um sistema como a sua probabilidade em executar as tarefas programadas de forma satisfatória, sem falhas e dentro dos limites de desempenho especificados. A confiabilidade dos sistemas fotovoltaicos é essencial para obter eletricidade de baixo custo, reduzir os custos de O&M, além de estender a vida útil e a disponibilidade do sistema (LORENZO et al., 2020).

A confiabilidade de usinas FV pode ser obtida através de um projeto adequado junto de um protocolo de O&M otimizado. As atividades de O&M podem melhorar os contratos de compra de energia elétrica, mitigar os riscos e aumentar o retorno sobre o investimento. Portanto, a pesquisa e o desenvolvimento de ferramentas modernas para o monitoramento e a avaliação de desempenho são essenciais para melhorar a confiabilidade dos sistemas FV e, conseqüentemente, construir a confiança do mercado (CALLEJO; SAAVEDRA; GÓMEZ, 2019).

Avaliar o desempenho de instalações fotovoltaicas é uma tarefa crítica e desafiadora, especialmente em usinas. Fatores como a presença de nuvens e componentes na atmosfera que afetam a translucidez do ar, assim como o curso diário e sazonal do Sol, causados pelos movimentos de rotação e translação da Terra, além de todos os fatores nocivos que estão presentes no ambiente circundante à matriz acabam impactando diretamente na geração de eletricidade. Além disso, o arranjo fotovoltaico está sujeito a um processo de degradação que pode ser acelerado por diferentes fatores, tais como: a umidade, a temperatura, o granizo, a exposição a surtos eletromagnéticos e a baixa qualidade dos processos de manufatura, de instalação, de embalagem, de armazenamento e de transporte (HARROU et al., 2018).

As falhas nos módulos fotovoltaicos são difíceis de precaver e podem resultar em perdas de energia, desligamento do sistema ou até mesmo em sérias questões de segurança. Portanto, é crucial detectar e identificar as possíveis falhas da forma mais breve possível. Recomenda-se que o desempenho das usinas seja monitorado desde o comissionamento e se perpetue por toda a vida útil da instalação.

Atualmente, existem várias soluções comerciais para o monitoramento fotovoltaico. Porém, essas ferramentas geralmente necessitam de um longo período de avaliações em campo e são precárias quanto a identificação das causas do baixo desempenho. Por outro lado, conforme já apresentado, a literatura agrega uma série de ferramentas e metodologias que possuem a capacidade de diagnosticar corretamente às instalações fotovoltaicas, mas essas soluções normalmente precisam ser aperfeiçoadas para se tornarem produtos comerciais.

A literatura mostra que a medição da curva I-V agrega diversas vantagens ao processo de monitoramento, sendo considerada por muitos autores como a medição de desempenho mais completa para os arranjos FV. Entre os principais aspectos positivos da análise da curva I-V se destaca a possibilidade de identificar alguns parâmetros elétricos relevantes, tais como: a corrente

e a tensão no ponto de máxima potência, a potência máxima, a corrente de curto-circuito e a tensão de circuito aberto. Além disso, a análise da curva permite calcular quantitativamente as perdas de energia e determinar o valor das resistências série e paralela e do fator de forma.

Apesar do uso de traçadores de curvas I-V estar consolidado no mercado fotovoltaico, estes dispositivos ainda são manuais e implicam numa longa tarefa ao operador - exigem a desconexão física, a medição individual de cada uma das séries fotovoltaicas na caixa de junção e a reconexão das séries. As ações de desconexão e reconexão são altamente indesejáveis, pois aumentam o custo e requerem mão de obra especializada. Em alguns casos, a desconexão exige o desligamento do inversor, impactando na geração de energia de forma parcial ou total da usina. Destaca-se que usinas de grande porte dispõem de milhares de séries fotovoltaicas, o que torna essa atividade extenuante e onerosa.

Para ilustrar o número de séries fotovoltaicas que compõem uma usina consideram-se dois casos-exemplo. Uma primeira usina com potência de 5 MW e outra com 500 MW. Assumindo que as usinas são equipadas com módulos de 450 watts com tensão no ponto de máxima potência de 40 volts. Logo, a primeira usina possui mais de 10 mil módulos e a segunda mais de 1 milhão de módulos. Assumindo que uma série fotovoltaica possui normalmente 1.000 V, então cada série é composta de 25 módulos. Logo, a primeira usina possui mais de 400 séries e a segunda mais de 40.000 séries.

Percebe-se que até mesmo usinas de pequeno porte possuem um quantitativo expressivo de séries fotovoltaicas. Portanto, medir manualmente a curva I-V de séries fotovoltaicas de uma usina pode demandar muito tempo a depender do tamanho da usina, do número de equipamentos e de operadores, além das condições climáticas favoráveis. Consequentemente, uma parte da matriz fotovoltaica pode apresentar uma falha por um longo período até que uma nova curva I-V seja adquirida e analisada, o que impacta diretamente no resultado operacional da usina.

Além disso, a medição manual de séries fotovoltaicas envolve a exposição dos operadores a circuitos energizados com altas tensões e correntes potencialmente letais. Por fim, deve-se considerar que as usinas possuem séries fotovoltaicas com cabos de longa extensão, o que resulta em um circuito altamente indutivo devido ao comprimento do cabo. Essa característica, associada à operação em corrente contínua, pode resultar em arcos elétricos no momento da abertura destes circuitos que, além dos riscos elétricos, provocam acelerada degradação dos componentes aos quais os mesmos estão submetidos.

Constata-se, dessa forma que, embora existam métodos consolidados para rastrear as curvas I-V em usinas fotovoltaicas, essa tarefa é custosa, periculosa e complexa se houver um conjunto muito grande de séries. Também observa-se a carência de equipamentos comerciais com capacidade de processar um grande conjunto de dados e avaliar o desempenho de usinas fotovoltaicas de forma adequada. Logo, justifica-se o desenvolvimento deste trabalho como a busca de uma contribuição para agregar valor nas atividades de O&M através do auxílio no processo de monitoramento contínuo e avaliação de desempenho da matriz fotovoltaica. A metodologia proposta realiza a análise automática das curvas I-V de séries fotovoltaicas e com o

auxílio de modelos matemáticos e técnicas de IA permite identificar os fatores de degradação e classificar as condições operacionais de séries FV.

A revisão bibliográfica relacionada ao tema buscou referências que envolvessem o projeto de traçadores de curvas I-V para aplicações fotovoltaicas. Logo, sob a perspectiva acadêmica, foi realizada uma pesquisa bibliográfica em agregadores de trabalhos científicos e nas principais bases de dados, como: portal de periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), IEEE, Google Acadêmico, Science Direct, Scopus, Scielo, entre outros. A metodologia utilizada para o desenvolvimento da bibliometria foi uma busca por títulos através da seguinte combinação de palavras-chave:

(“I-V tracer” OR “IV tracer” OR “I-V tracing” OR “IV tracing” OR “curve tracer” OR “characteristic tracer” OR “characteristic curve” OR “I-V characteristics” OR “IV characteristics” OR “I-V fault” OR “IV fault” OR “I-V failure” OR “IV failure” OR “fault tracer” OR “failure tracer” OR “fault tracing” OR “failure tracing” OR “I-V monitoring” OR “IV monitoring” OR “I-V diagnosis” OR “IV diagnosis” OR “tracer monitoring” OR “tracer diagnosis”) AND (“solar” OR “PV” OR “photovoltaics” OR “photovoltaic”).

A combinação resultou em um total de 250 documentos. Em um primeiro momento, a seleção ocorreu através dos trabalhos publicados no período de 2015 até 2021, resultando em 118 documentos. Posteriormente, foram excluídos os trabalhos publicados em congressos e selecionados apenas aqueles publicados em revista científicas, restando 72 documentos. Com base na análise dos títulos e do resumo destes trabalhos foi possível selecionar 17 artigos com maior pertinência ao tema. As publicações selecionadas estão ordenadas na Tabela 1 de acordo com o fator de impacto (F.I.) do periódico.

Os autores Spertino et al. (2015) e Ramaprabha et al. (2015) projetaram um traçador de curvas I-V com o objetivo de estimar o ponto de máxima potência de geradores fotovoltaicos, enquanto que os demais desenvolveram soluções para avaliar o desempenho desses geradores. As soluções variam quanto: a carga utilizada, a conexão do traçador com os módulos FV, o local de armazenamento dos dados adquiridos e a potência máxima suportada pelo traçador de curvas. O equipamento projetado por Chen et al. (2020) mostrou-se capaz de rastrear a curva I-V de uma série FV de 1,8 kW, sendo este o maior nível de potência entre as publicações analisadas. A síntese dos projetos contidos nas publicações selecionadas está organizada na Tabela 2.

Sob a perspectiva de inovação, foi realizada uma bibliometria com uma busca sistemática nas principais bases de patentes nacionais e internacionais através do sistema Orbit. A metodologia utilizada empregou a busca por títulos através da mesma combinação de palavras-chave que foi usada na busca dos trabalhos acadêmicos. Através desta combinação, um total de 43 patentes foram encontradas, a seleção deu-se a partir da leitura das 23 patentes ativas, onde destacaram-se 9 patentes com maior centralidade de grau com o tema deste trabalho, as patentes selecionadas são elencadas na Tabela 3.

Tabela 1 – Publicações selecionadas que envolvem o projeto de traçadores de curvas I-V.

Título / Referência	F. I.
Design and implementation of a photovoltaic I-V curve tracer: Solar modules characterization under real operating conditions. Ref.: Amiry et al. (2018).	9,709
Development of a capacitor charging based quick I-V curve tracer with automatic parameter extraction for photovoltaic arrays. Ref.: Chen et al. (2020).	9,709
Implementation of a plug and play I-V curve tracer dedicated to characterization and diagnosis of PV modules under real operating conditions. Ref.: Sarikh et al. (2020).	9,709
An IoT-based remote IV tracing system for analysis of city-wide solar power facilities. Ref.: Shapsough et al. (2020).	7,587
Portable and wireless IV-curve tracer for >5 kV organic photovoltaic modules. Ref.: García-Valverde et al. (2016).	7,267
Capacitor charging method for I–V curve tracer and MPPT in photovoltaic systems. Ref.: Spertino et al. (2015).	5,742
Development of an electronic load I-V curve tracer to investigate the impact of Harmattan aerosol loading on PV module performance in southwest Nigeria. Ref.: Willoughby e Osinowo (2018).	5,742
Configurable IoT open-source hardware and software I-V curve tracer for photovoltaic generators. Ref.: González, Portalo e Calderón (2021).	4,350
Design of a portable photovoltaic I–V curve tracer based on the DC–DC converter method. Ref.: Pereira et al. (2021).	3,887
Design and development of low cost, portable, on-field I-V curve tracer based on capacitor loading for high power rated solar photovoltaic modules. Ref.: Sayyad e Nasikkar (2021).	3,367
Low-cost I–V tracer for PV modules under real operating conditions. Ref.: Cáceres et al. (2020).	3,343
Simplified I-V characteristic tester for photovoltaic modules using a DC-DC Boost converter. Ref.: Khatib, Elmenreich e Mohamed (2017).	3,215
Internet of things (IoT) based i-v curve tracer for photovoltaic monitoring systems. Ref.: Chi et al. (2019).	1,294
Capacitor load based I–V curve tracer for performance characterisation of the solar photovoltaic system. Ref.: Sayyad e Nasikkar (2020).	1,204
Design and implementation of efficient curve tracer for photovoltaic system under partial shaded conditions. Ref.: Ramaprabha et al. (2015).	1,000
Plotting characteristic curves of photovoltaic modules. Ref.: Silva et al. (2021).	0,671
Low-cost electronics for online I-V tracing at photovoltaic module level: Development of two strategies and comparison between them. Ref.: Morales-Aragonés et al. (2021).	0,600

Fonte: Elaborada pelo autor (2020).

Tabela 2 – Síntese dos traçadores descritos nas publicações elencadas na Tabela 1.

Referência	Carga	Conexão	Armaz.	Validação
Amiry et al. (2018)	Eletrônica - Mosfet	Manual	Local	Módulo FV, 5 W
Chen et al. (2020)	Capacitiva	Manual	Local	Série FV, 1,8 kW
Sarikh et al. (2020)	Eletrônica - Mosfet	Automática	Nuvem	Módulo FV, 255 W
Shapsough et al. (2020)	Capacitiva	Manual	Nuvem	Módulo FV, 100 W
García-Valverde et al. (2016)	Capacitiva	Automática	Local	Módulo FV, 560 W
Spertino et al. (2015)	Capacitiva	Automática	Não possui	Série FV, 615 W
Willoughby e Osinowo (2018)	Eletrônica - Mosfet	Manual	Local	Módulo FV, 80 W
González, Portalo e Calderón (2021)	Eletrônica - Prog.	Manual	Nuvem	Série FV, 1,1 kW
Pereira et al. (2021)	Conversor Cúk	Manual	Local	Módulo FV, 260 W
Sayyad e Nasikkar (2021)	Capacitiva	Manual	Nuvem	Série FV, 520 W
Cáceres et al. (2020)	Capacitiva	Automática	Local	Módulo FV, 250 W
Khatib, Elmenreich e Mohamed (2017)	Conversor Boost	Automática	Local	Módulo FV, 120 W
Chi et al. (2019)	Conversor SEPIC	Automática	Local	Módulo FV, 100 W
Sayyad e Nasikkar (2020)	Capacitiva	Manual	Nuvem	Módulo FV, 60 W
Ramaprabha et al. (2015)	Conversor Boost	Automática	Não possui	Módulo FV, 72 W
Silva et al. (2021)	Conversor SEPIC	Manual	Local	Módulo FV, 10 W
Morales-Aragonés et al. (2021)	Eletrônica - Mosfet	Automática	Local	Módulo FV, 180 W

Fonte: Elaborada pelo autor (2020).

Tabela 3 – Patentes selecionadas que envolvem o projeto de traçadores de curvas I-V.

Título	Ano	Número
System and method for remotely acquiring output characteristic curve of photovoltaic cell	2021	CN113489458
Method for determining a characteristic curve of a photovoltaic (pv) string, dc/dc converter, and photovoltaic system suitable for carrying out the method	2019	WO2020/254029
Online i-v tracer for per string monitoring and maintenance of photovoltaic (pv) panels	2019	IN201841037650
Curve tracer and portable electrical characterizer for testing photovoltaic modules	2019	BR102019020934
Photovoltaic module output characteristic curve obtaining circuit and method and photovoltaic power generation system	2018	CN108832894
Photovoltaic array iv characteristic curve scanning and parameter identification system and method	2018	CN108111125
Photovoltaic board output characteristic curve tester	2017	CN206922717
Distributed photovoltaic module string and module iv characteristic curve on-line measurement system	2016	CN106357220
Wireless current-voltage tracer with uninterrupted by pass system and method	2015	US8952715

Fonte: Elaborada pelo autor (2020).

Assim como nos trabalhos acadêmicos, as patentes apresentam variações quanto a estrutura e os recursos do traçador de curvas I-V. A seguir, apresenta-se uma síntese das patentes selecionadas:

CN113489458 Aquisição da curva I-V de módulos FV. Cada módulo é conectado a um relé que permite a sua desconexão da matriz. O traçador de curvas utiliza uma carga eletrônica composta por transistores bipolares. A visualização dos resultados ocorre através de uma plataforma Web (KANJIAN; ZIYANG; ZENGXIANG, 2021).

WO2020/254029 Aquisição da curva I-V de séries FV. O inversor é fabricado com um circuito para aquisição das curvas I-V. Cada série fotovoltaica é conectada a um conversor c.c./c.c. que opera como otimizador de potência e possui três modos de operação, sendo eles: i) rastreamento do ponto de máxima potência, ii) aquisição da curva I-V, iii) desconexão (VIOTTO; HOPF; SCHROPP, 2019).

IN201841037650 Aquisição da curva I-V de séries FV. O traçador de curvas é instalado na caixa de junção da matriz e utiliza uma solução composta de quatro transistores e dois capacitores que permite armazenar energia em um capacitor e depois utilizá-la para alimentar a matriz

enquanto a série fotovoltaica está sob teste, o que reduz as perdas de desconexão da série. A comparação entre a curva adquirida com uma curva de referência fornece cronogramas de limpeza, diagnósticos de falhas e alertas de manutenção (JOGLEKAR, 2019).

BR102019020934 Aquisição da curva I-V de módulos FV. Traçador de curvas portátil que utiliza como carga um conversor c.c./c.c. com topologia Cúk. A invenção traça as curvas I-V e P-V, determina as grandezas nos três pontos de interesse da curva I-V e calcula os cinco parâmetros que descrevem o modelo matemático do módulo fotovoltaico (MARTINS et al., 2019).

CN108832894 Aquisição da curva I-V de módulos FV. Cada módulo é equipado com um dispositivo para aquisição da curva I-V. Sendo este dispositivo composto por dois transistores que atuam como comutadores, uma carga utilizada para aquisição da curva e um circuito de *by-pass* (YANFEI; HUA; ZONGJUN, 2018).

CN108111125 Aquisição da curva I-V de matrizes FV. O traçador de curvas utiliza uma carga capacitiva e pode ser construído em formato portátil ou ser instalado na caixa de junção da usina. Um algoritmo identifica os parâmetros que descrevem o modelo matemático da matriz fotovoltaica (ZHICONG et al., 2018).

CN206922717 Aquisição da curva I-V de módulos FV. Um conversor c.c./c.c. Buck-Boost é utilizado na aquisição das curvas I-V. O traçador de curvas é portátil e permite mensurar os valores da curva próximos ao ponto da corrente de curto-circuito (HUIXIN, 2017).

CN106357220 Aquisição da curva I-V de séries FV. O traçador de curvas é instalado na caixa de junção da matriz fotovoltaica e utiliza uma carga eletrônica (IGBT) para rastrear a curva I-V. As séries FV são desconectadas da matriz através de relés e um computador local armazena os dados mensurados (ZHICONG et al., 2016).

US8952715 Aquisição da curva I-V de módulos ou séries FV. Um sistema automático permite a medição da curva I-V sem a interferência de operadores. Possui uma solução para carregar um capacitor e depois utilizar esta energia para alimentar a matriz fotovoltaica enquanto o módulo está sob teste. Neste caso, cada dispositivo fotovoltaico a ser ensaiado é equipado com sensores de corrente e tensão (KELLEN; PETER, 2012).

Tanto as publicações acadêmicas como as patentes mostram que os traçadores de curvas podem ser projetados com diferentes recursos e configurações, sendo que cada uma destas possibilidades apresenta vantagens e desvantagens dependendo da aplicação desejada. As publicações mostram um equilíbrio no número de projetos para dispositivos portáteis e dispositivos para serem integrados a usinas fotovoltaicas. Em geral, os projetos divergem em relação ao elemento utilizado como carga, mas nota-se uma preferência para cargas capacitivas quando o objetivo é rastrear curvas I-V de de séries fotovoltaicas (alta potência). Os projetos são similares quanto à

importância e à necessidade da conectividade e do uso da Internet no controle das operações dos traçadores de curvas I-V.

Além das publicações acadêmicas e das patentes supracitadas existem outras publicações que estão correlacionadas com o tema deste trabalho e merecem destaque. São elas:

- Os trabalhos propostos por Joglekar e Hegde (2018) e Joglekar (2020) implicam em um traçador de curvas I-V que fica instalado na caixa de junção da usina. O traçador possui uma topologia com dois braços, ambos compostos por dois transistores e um capacitor. Enquanto o primeiro braço executa a aquisição da curva I-V, o segundo mantém a alimentação da matriz fotovoltaica constante. Em uma nova aquisição, inverte-se a função de cada braço. Essa configuração tem o objetivo de reduzir as perdas de desconexão das séries FV. A solução foi validada em uma matriz composta por uma única série.
- A patente registrada por Dunn, Gostein e Stueve (2012) descreve uma solução para a aquisição de curvas I-V de séries e módulos fotovoltaicos. A solução patenteada apresenta algumas semelhanças com o hardware que está sendo proposto neste trabalho. No entanto, por se tratar de uma patente, o traçador de curvas I-V é descrito de forma conceitual e não tecnológica. Logo, o documento não especifica a tecnologia da carga a ser utilizada pelo traçador, nem os dispositivos utilizados como controladores e armazenadores de dados, nem os protocolos de comunicação e as tecnologias empregadas no processo de comutação da séries fotovoltaicas.

Por fim, conclui-se que há uma tendência no uso de traçadores de curvas I-V para o monitoramento de séries fotovoltaicas. Entretanto, nenhum dos trabalhos propôs o desenvolvimento de um traçador de curvas I-V automático e que seja integrado a uma metodologia para diagnóstico da geração, cujo resultado indique as possíveis causas de degradação das séries fotovoltaicas e possa ser acessado remotamente. Assim, pode-se afirmar que não foram encontradas pesquisas com o mesmo objetivo e metodologia daquelas que foram propostas neste trabalho.

1.4 CONTRIBUIÇÕES DO TRABALHO

As principais contribuições propostas por este trabalho são:

- Traçador de curvas I-V automático e instalado na caixa de junção de usinas fotovoltaicas. Através de módulos comutadores torna-se possível a aquisição da curva I-V de cada uma das séries FV que compõem a matriz. A medição é realizada em alta velocidade, o período de aquisição de uma curva I-V ocorre em cerca de 100 ms, evitando, dentro do possível, que ocorram variações consideráveis nas condições climáticas durante o ensaio. A operação automática e a alta velocidade de aquisição possibilitam que todas as séries fotovoltaicas tenham suas curvas I-V rastreadas em diversos momentos ao longo de um mesmo dia. Deve-se enfatizar que essa característica viabiliza o uso de

traçadores de curvas I-V no monitoramento contínuo de usinas. As curvas I-V são armazenadas em um servidor local e/ou remoto. Por fim, destaca-se que, a solução proposta elimina a necessidade de operadores entrarem em contato com os circuitos energizados e potencialmente letais.

- Metodologia para diagnosticar a geração de usinas fotovoltaicas que permite auxiliar no comissionamento e no monitoramento contínuo da usina. A metodologia é dividida em duas etapas, sendo a primeira responsável por detectar situações de baixo desempenho e quantificar as perdas através da comparação entre as curvas I-V mensuradas com curvas modeladas. A segunda etapa realiza a identificação dos fatores de degradação e classifica as condições operacionais de cada uma das séries FV. Uma rede neural artificial possibilita que as séries FV sejam classificadas em situações de sujidade, sombreamento e condução dos diodos de *by-pass*. Destaca-se que, a avaliação de desempenho é realizada automaticamente e os resultados são disponibilizados um servidor local e/ou remoto.

Vale ressaltar que a integração do traçador de curvas I-V com a metodologia para avaliação de desempenho viabiliza o monitoramento automático de usinas fotovoltaicas. Além disso, a estratégia de disponibilizar as curvas I-V e o diagnóstico da geração na nuvem permite que as usinas operem sem uma equipe de O&M presente no local, ou então, com uma equipe reduzida. Afinal, o monitoramento é realizado de forma contínua e automática, sendo papel da equipe de O&M agir apenas quando for diagnosticada uma situação de baixo desempenho.

Além disso, deve-se salientar que a solução proposta pode ser instalada em usinas fotovoltaicas novas ou então em plantas já existentes. A solução também possui capacidade de escalonamento, ou seja, novas séries FV ou sensores podem ser adicionados sem a necessidade de alteração no hardware já existente, desde que seja respeitada a quantidade máxima de dispositivos do protocolo de comunicação.

Assim sendo, conclui-se que, embora o mercado já disponha de equipamentos comerciais para traçar curvas I-V de usinas fotovoltaicas, a solução proposta permite: diagnosticar o desempenho de usinas, otimizar as atividades e minimizar os custos de O&M e maximizar a geração de energia. Consequentemente, as contribuições deste trabalho implicam de forma direta no aumento do retorno financeiro de usinas fotovoltaicas.

1.5 DELIMITAÇÕES DO TRABALHO

Os sistemas fotovoltaicos possuem diversos parâmetros que variam de acordo com cada instalação, por exemplo: a potência do sistema; a tecnologia dos módulos; a configuração das conexões em série e em paralelo dos módulos, etc. Logo, para o desenvolvimento deste trabalho algumas delimitações precisam ser previamente definidas, sendo elas:

- O traçador de curvas I-V proposto foi projetado para o rastreamento de séries fotovoltaicas com módulos de silício cristalino, sendo esta a tecnologia comercialmente

mais empregada na presente data. A técnica possivelmente pode ser estendida à outras tecnologias, mas este ponto não é considerado nesse estudo;

- O método proposto não se aplica em sistemas fotovoltaicos que utilizam conversores integrados à módulos fotovoltaicos;
- O quantitativo de séries fotovoltaicas monitoradas deve respeitar os limites do protocolo de comunicação Modbus. Esse quantitativo pode ser aumentado pelo uso de repetidores de sinal, ou então, pelo emprego de dois ou mais traçadores de curvas I-V.
- A metodologia é proposta para avaliar o desempenho no lado c.c. dos sistemas fotovoltaicos. O traçador de curvas I-V pode ser instalado nas caixas de junção ou no eletrocentro. Logo, as falhas que ocorrem a partir do traçador não são detectadas.

1.6 ESTRUTURA DO TRABALHO

O presente trabalho está estruturado em 6 capítulos, conforme mostra a Figura 2, sendo descritos abaixo:

Capítulo 2 apresenta o referencial teórico e possui o objetivo de embasar o leitor em relação ao monitoramento e o diagnóstico da geração de usinas fotovoltaicas. O capítulo discorre sobre os fatores que impactam na geração, os detalhes técnicos da medição dos parâmetros elétricos e climáticos, a importância das curvas I-V e os principais métodos de modelagem de arranjos FV.

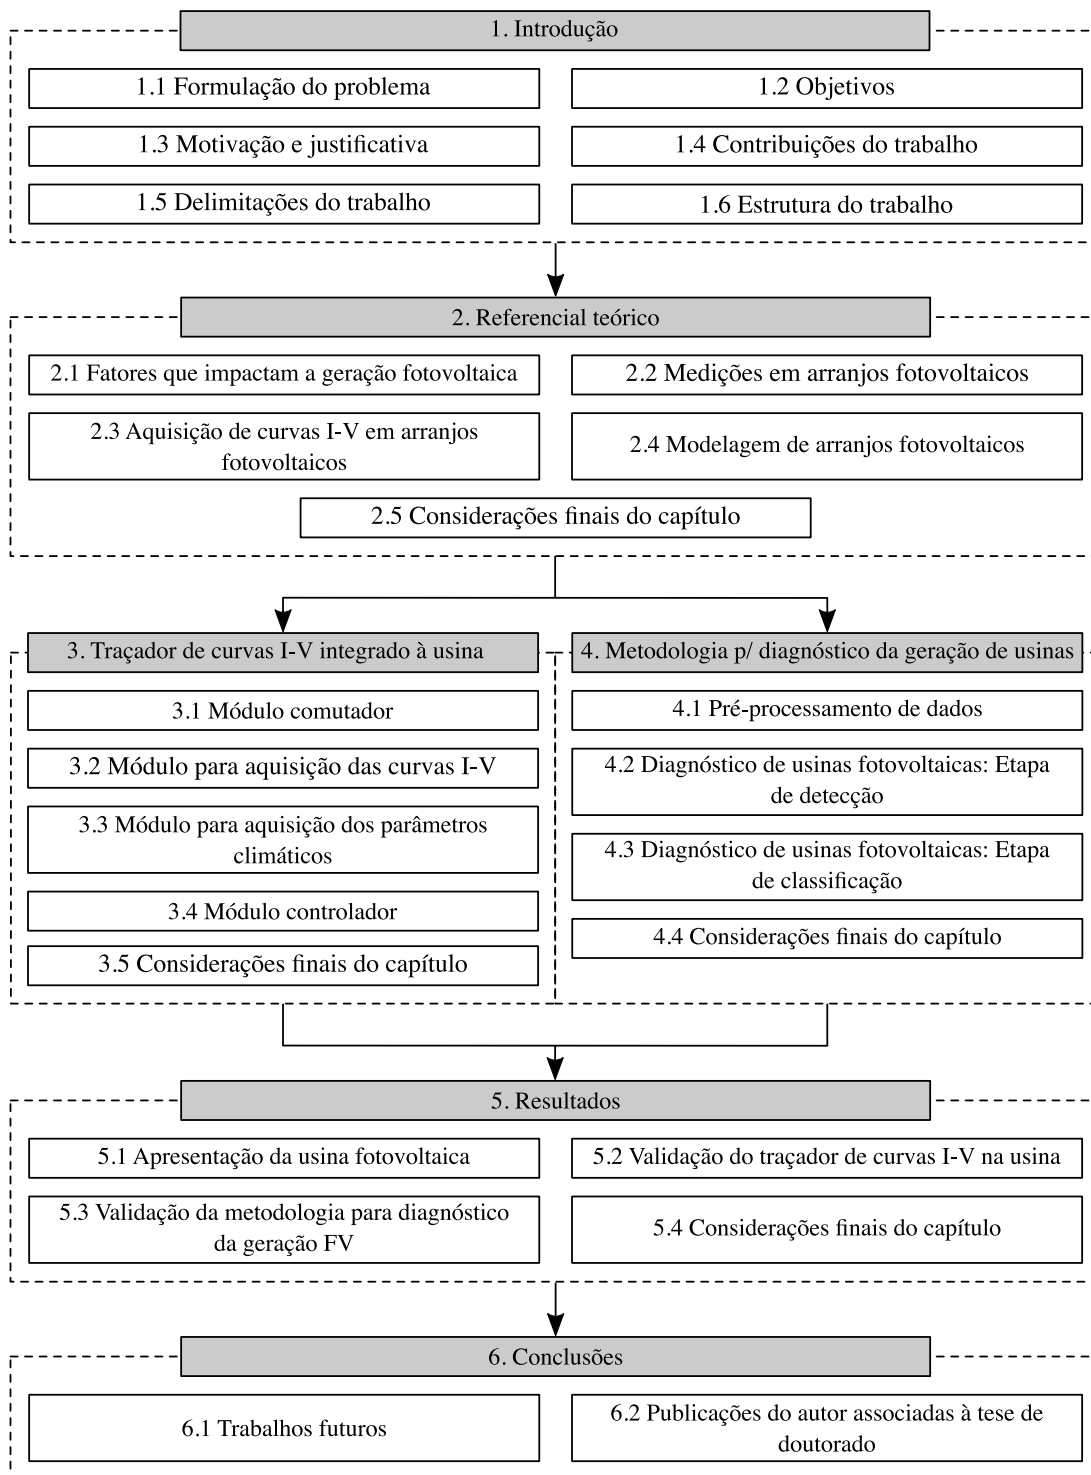
Capítulo 3 propõe o traçador de curvas I-V automático e integrado à caixa de junção de usinas fotovoltaicas. O capítulo expõe o projeto de cada módulo que compõem a solução proposta, sendo eles: os módulos comutadores, o módulo para aquisição das curvas I-V, o módulo para aquisição dos parâmetros climáticos e o módulo controlador.

Capítulo 4 propõe a metodologia para diagnóstico da geração fotovoltaica. O capítulo aborda a etapa de detecção de baixo desempenho e quantificação das perdas que ocorrem através da comparação entre as curvas I-V mensuradas e as curvas estimadas por um modelo matemático. Além da etapa de classificação das condições operacionais das séries FV que é realizada por uma rede neural artificial.

Capítulo 5 apresenta a validação do traçador de curvas I-V e da metodologia para diagnóstico da geração. O capítulo explana os resultados experimentais obtidos em uma usina fotovoltaica real, não apenas em escala laboratorial, o que comprova a adequação das contribuições que estão sendo propostas.

Capítulo 6 disserta sobre as conclusões deste trabalho considerando os resultados experimentais. Adicionalmente, são discutidas as perspectivas para trabalhos futuros.

Figura 2 – Estrutura do trabalho.



Fonte: Elaborada pelo autor (2023).


2 REFERENCIAL TEÓRICO

O capítulo a seguir tem o objetivo de embasar o leitor em relação ao monitoramento e a avaliação de desempenho de usinas fotovoltaicas. Em um primeiro momento são relatados os principais fatores construtivos, naturais e operacionais que impactam na geração fotovoltaica. A seguir, discorre-se sobre a metodologia que deve ser adotada para a medição, em campo, dos parâmetros elétricos e climáticos. Posteriormente, são abordadas as informações mais relevantes sobre a aquisição de curvas I-V, como: as normas que regem o processo, as topologias dos circuitos e o processo de translação das curvas para uma condição padrão de temperatura e irradiância. Por fim, explana-se sobre a modelagem de arranjos fotovoltaicos e a aplicabilidade desses modelos no monitoramento fotovoltaico, onde são discutidas as vantagens e desvantagens dos modelos baseados em inteligência artificial e dos modelos baseados em circuitos elétricos.

2.1 FATORES QUE IMPACTAM A GERAÇÃO FOTOVOLTAICA

A geração fotovoltaica destaca-se pela sua característica renovável, sua longa vida útil, a necessidade de pouca manutenção, a operação silenciosa e limpa. Contudo, os dispositivos fotovoltaicos apresentam geração intermitente, baixa densidade de energia, custos elevados de instalação e dependem das condições meteorológicas. Alterações na irradiância ocasionam um efeito linear e proporcional na potência máxima de um módulo, conforme mostra a Figura 3. O aumento da irradiância implica no aumento considerável da corrente, sem alterar significativamente a tensão.

Figura 3 – Influência da irradiação solar na curva I-V de um módulo fotovoltaico.




Fonte: Adaptado de Seaward (2012).

A radiação solar global que atinge os módulos é composta de três componentes: direta, difusa e refletida, conforme mostra a Figura 4. O componente que atinge diretamente os módulos, sem se espalhar pelo ambiente, é chamado de radiação normal ou direta. A radiação difusa é

definida como a parcela que atinge os módulos indiretamente, essa situação pode ser originada por difração nas nuvens, pela presença de nevoeiros, por poeiras em suspensão na atmosfera ou outros obstáculos. A radiação refletida depende da refletividade do ambiente circundante, sendo influenciada pela paisagem, em especial pela presença de vegetação, edifícios e inclusive pelo índice de refletividade do solo. As superfícies altamente reflexivas devem ser removidas das proximidades do arranjo fotovoltaico, pois podem influenciar na aferição da irradiância e, conseqüentemente, na avaliação de desempenho. A soma dos três componentes da irradiância é chamada de irradiância total ou global (REZK et al., 2017).


Figura 4 – Classificação da radiação solar incidente sobre os módulos fotovoltaicos.



A geração fotovoltaica também é influenciada pela temperatura de operação das células. O aumento da temperatura causa a redução da tensão e da potência, além de produzir um ligeiro aumento, quase imperceptível, na corrente dos módulos. Destaca-se que os coeficientes de temperatura, que são fornecidos nos catálogos dos módulos, relacionam os efeitos da temperatura na tensão, na corrente e na potência das células. Módulos de silício cristalino possuem, de forma aproximada, o coeficiente de temperatura para tensão de $-0,4\%/^{\circ}\text{C}$, para corrente de curto-circuito de $+0,04\%/^{\circ}\text{C}$ e para potência máxima de $-0,45\%/^{\circ}\text{C}$. Os coeficientes para potência e tensão são negativos pois esses parâmetros diminuem conforme o aumento da temperatura, essa situação é ilustrada pela Figura 5 (SEAWARD, 2012).

Além da irradiação solar e da temperatura, a geração fotovoltaica também é influenciada pela eficiência das células, a qual está relacionada com o tipo de tecnologia utilizada. Atualmente, existem inúmeras tecnologias, entre as mais populares estão as monocristalinas, as policristalinas e as de filmes finos de silício amorfo. As tecnologias de silício cristalino representam mais de 97% da produção total de células fotovoltaicas. As células monocristalinas possuem eficiência entre 20% a 24%, enquanto as policristalinas alcançam de 18% a 20%. As células policristalinas são as mais populares devido ao menor custo de fabricação (MASSON; KAIZUKA et al., 2019).

Figura 5 – Influência da temperatura de operação na curva I-V de um módulo fotovoltaico.



Fonte: Elaborada pelo autor (2019).

As instalações fotovoltaicas estão sujeitas a fatores que podem vir a degradar o seu desempenho. Por exemplo, a presença de módulos defeituosos ou, até mesmo, o acúmulo de poeira sobre os módulos podem impactar na geração fotovoltaica. A seguir, os principais fatores que degradam o desempenho de instalações fotovoltaicas serão relatados. Para facilitar a organização, estes fatores foram classificados em dois conjuntos: i) os fatores construtivos e naturais que impactam na geração, ii) as falhas operacionais que impactam na geração.

2.1.1 Fatores construtivos e naturais que impactam a geração

Os fatores que degradam a geração fotovoltaica e que fazem parte deste conjunto estão presentes em todas as usinas fotovoltaicas. Estes fatores, quando detectados, não exigem um processo imediato de manutenção corretiva, pois estão correlacionadas com os fatores construtivos dos módulos e com fatores naturais. Assim sendo, podem ser considerados como situações intrínsecas a todas as instalações fotovoltaicas. A seguir, os principais fatores construtivos e naturais que impactam na geração fotovoltaica são apresentados:

Incompatibilidade de módulos fotovoltaicos também denominada de *mismatch*, está relacionada com a fabricação dos módulos fotovoltaicos, em razão destes dispositivos serem produzidos com características de tensão e corrente ligeiramente distintas. A Norma IEC 61215 exige que a potência do módulo esteja dentro de $\pm 3\%$ da sua potência de placa. Uma consequência da incompatibilidade dos módulos está na limitação da corrente elétrica, pois em uma série fotovoltaica a corrente de todos os módulos deve ser idêntica. No caso de módulos incompatíveis, aquele com a corrente mais baixa limitará a corrente de toda a série (SEAWARD, 2012).

Degradação induzida pela luz os módulos fotovoltaicos degradam-se naturalmente devido à exposição a irradiação solar. A degradação induzida pela luz (LID, do inglês *Light Induced*

Degradation) causa uma redução da corrente de curto-circuito e da tensão de circuito aberto dos módulos. As perdas de energia atingem uma taxa de aproximadamente 3% no primeiro ano de uso. A partir daí, ocorre um fenômeno de estabilização e as perdas nos anos subsequentes atingem taxas em torno de 0,8%. A degradação das células fotovoltaicas por LID é altamente dependente da tecnologia e da qualidade dos materiais utilizados no processo de fabricação. Por exemplo, as células fotovoltaicas do tipo PERC (*Passivated Emitter Rear Cell* - Emissor passivado e contato traseiro) estão sujeitas a um efeito LID mais significativo e as perdas podem atingir uma taxa de 10% (SILVA; GUL; CHAUDHRY, 2021; SILVA, 2015; SHAH; KHAN; KHAN, 2019).

Degradação induzida por luz e temperatura elevada outra forma de degradação natural dos módulos fotovoltaicos é a degradação induzida por luz e temperatura elevada (LeTID, do inglês *Light and elevated Temperature Induced Degradation*). Esse fenômeno foi descoberto pela primeira vez em 2012 e causa perda de desempenho no caso de exposição das células FV à luz solar durante centenas de horas e à uma temperatura elevada, superior à 50 °C. Destaca-se que a LeTID não ocorre se o módulo operar a uma temperatura abaixo de 50 °C, ou se operar acima dessa temperatura durante um curto período (SILVA; GUL; CHAUDHRY, 2021; KERSTEN et al., 2015)

Sujidade o acúmulo de partículas que cobrem a superfície dos módulos, como terra, areia, folhas, excrementos de pássaros, poluentes industriais e outros, impedem que a radiação solar atinja as células fotovoltaicas e, conseqüentemente, a eficiência da instalação é reduzida. A quantidade de sujeira incrustada na superfície dos módulos é influenciada principalmente pelas condições climáticas, mas a qualidade do vidro também deve ser considerada. A sujeira influencia no custo da eletricidade de duas formas: elevando o custo de manutenção (limpeza periódica) e reduzindo a energia produzida. Algumas partes do mundo acabam sendo muito mais afetadas pela sujidade. Pesquisas apontam que sistemas fotovoltaicos localizados em regiões áridas com baixa precipitação podem sofrer perdas de 20% ao ano devido a sujeira acumulada. A frequência ideal para limpeza de módulos instalados em regiões desérticas é de aproximadamente 20 dias, quando a redução da potência é igual a 5% e a concentração de partículas atinge 100 g/cm³. No Brasil, um estudo realizado por Rosa e Souto (2021) analisou os benefícios econômicos da limpeza e o prejuízo técnico-financeiro da não realização da limpeza. Os resultados mostram a importância de realizar esse processo, em especial, nos períodos secos do ano. O mercado fotovoltaico tem apresentado uma série de estratégias para a limpeza de instalações fotovoltaicas que vão desde o uso de robôs automatizados, até o uso de métodos de vibração ou técnicas de revestimento (STEIN, 2017; CHIANTORE; PAPAECONOMOU; DEGENER, 2018; SEAWARD, 2012; SHAH; KHAN; KHAN, 2019).

Sombreamento o sombreamento impede que a radiação solar atinja as células fotovoltaicas e, conseqüentemente, impacta na geração de energia. A causa pode se dar por fatores naturais,

como a presença de nuvens ou excrementos de pássaros. Contudo, existem situações em que a causa está em objetos do ambiente circundante, como edifícios, postes, árvores e outras partes da própria matriz. Nesses casos, o sombreamento pode ser considerado como um fator operacional, pois essas conjunturas devem ser previstas no projeto do arranjo fotovoltaico. O sombreamento pode ser classificado em: i) parcial, quando atinge apenas uma determinada região da matriz; ii) total, quando cobre a matriz integralmente. No caso do sombreamento parcial, se uma pequena parcela da matriz for sombreada a geração de energia já pode ser impactada significativamente. Sugere-se que instalações fotovoltaicas não sejam sombreadas entre as 9 h e as 15 h, uma vez que a maior parte da geração de energia ocorre nessa faixa de horário (SEAWARD, 2012).

Perdas nos circuitos c.c. e c.a. estão relacionadas com as perdas no cabeamento, nas conexões, nos fusíveis, nos diodos de bloqueio, nos interruptores e em quaisquer outros componentes presentes no circuito. Estima-se que o total das perdas no circuito c.c. é da ordem de 2% para a maioria das instalações fotovoltaicas. As perdas no lado c.a. estão localizadas entre o inversor e o medidor de energia elétrica. No caso de pequenas instalações fotovoltaicas, o medidor de energia encontra-se nas proximidades do inversor e as perdas são insignificantes. Por outro lado, algumas usinas possuem sistemas de distribuição e, tanto os cabos como os transformadores, acarretam em perdas que precisam ser consideradas (SEAWARD, 2012; STEIN, 2017).


2.1.2 Fatores operacionais que impactam a geração

Todas as usinas fotovoltaicas estão suscetíveis a fatores operacionais que impactam a geração de energia. No entanto, ao contrário da ocorrência dos fatores construtivos e naturais, neste caso, deve-se providenciar a manutenção corretiva dos dispositivos afetados para minimizar as perdas. A seguir, os principais fatores operacionais que impactam na geração fotovoltaica são apresentados.

Falha nos diodos de *by-pass* os módulos fotovoltaicos são formados por grupos de células e cada um destes grupos possui um diodo de *by-pass* conectado em paralelo. A função do diodo está em evitar o superaquecimento das células quando ocorrer o sombreamento parcial ou total do módulo. As células, quando sombreadas, operam de forma reversa, ao invés de produzir energia elas a dissipam. Logo, os diodos de *by-pass* atuam como válvulas que desviam o fluxo da corrente elétrica nas células sombreadas, conforme mostra a Figura 6. Por se tratar de um componente eletrônico, os diodos de *by-pass* estão suscetíveis a falhas. Quando ocorre uma falha de curto-circuito no diodo, a corrente gerada circula em um laço formado pelas células fotovoltaicas e o diodo, o que implica em menor eficiência do módulo fotovoltaico. Por outro lado, quando ocorre uma falha de circuito aberto no diodo e o módulo está sombreado, a corrente elétrica não pode ser desviada das células sombreadas e resulta em pontos quentes, também denominados de *hot-spots*. Os pontos

quentes deterioram o módulo e podem provocar a quebra e o derretimento da solda de interconexão das células, além de outros efeitos destrutivos (KHALIL et al., 2020).

Figura 6 – Representação de um módulo parcialmente sombreado com um diodo de *by-pass* em condução.



Fonte: Elaborada pelo autor (2019).

Degradação induzida por potencial trata-se de um fenômeno que ocorre devido a diferença de potencial entre as células fotovoltaicas e o aterramento. Em usinas, onde as séries FV alcançam uma tensão de circuito aberto superior a 1 kV, a diferença de potencial entre as células e a estrutura metálica do módulo, que é aterrada por questões de segurança, pode ser induzida. Neste caso, a diferença de potencial ocasiona correntes de fuga das células para a estrutura do módulo, o que implica em perda de desempenho. Existem algumas ações que podem mitigar a degradação induzida por potencial (PID, do inglês *Potential induced degradation*). Por exemplo, utilizar módulos fotovoltaicos que foram fabricados com materiais de maior qualidade, o que reduz a PID ao aumentar a resistência elétrica entre as células fotovoltaicas e a estrutura metálica do módulo (LORENZO et al., 2020; VINTURINI, 2019).

Trilha de caracol refere-se à uma descoloração que pode ocorrer tanto nas bordas das células fotovoltaicas como ao longo de fissuras celulares não-visíveis. A velocidade da descoloração depende das condições climáticas, sendo o processo acelerado em ambientes quentes. A trilha de caracol pode provocar rachaduras visíveis nas células e reduzir a eficiência do módulo (LORENZO et al., 2020).

Quebra e fissura das células são eventos que podem ocorrer em qualquer período da vida útil de um módulo, desde processo de fabricação, durante o transporte, na instalação ou então durante a operação devido à sobrecarga mecânica causada por eventos climáticos. Nos últimos anos, os fabricantes estão produzindo células mais finas e com a área cada vez maior, o que resulta em células mais sensíveis e mais frágeis que as convencionais (QUATER et al., 2014).

Falha nas conexões entre células as células fotovoltaicas são conectadas uma à outra no interior do módulo através de trilhas e soldas. Sobrecarga mecânica e pontos quentes podem

fazer com que a solda se rompa. Isso pode resultar no aumento da resistência série dos módulos ou até mesmo em situações de circuito aberto (TRIKI-LAHIANI; ABDELGHANI; SLAMA-BELKHODJA, 2018).

Corrosão interna e delaminação os componentes de um módulo fotovoltaico são laminados a vácuo para torná-los estanques ao ar e água. Porém, se o processo de laminação não for realizado da forma adequada pode ocorrer a delaminação do módulo, ou seja, o desprendimento dos componentes (camada de vidro, células e folha traseira). Neste caso, o módulo fica suscetível a penetração de umidade e contaminantes que podem resultar na criação de bolhas e no amarelamento da superfície dos módulos. Essa situação implica na reflexão da radiação solar e conseqüentemente na redução do desempenho do módulo. A penetração da umidade pode ocasionar a corrosão das partes metálicas e causar o aparecimento de correntes de fuga. Além disso, a folha traseira é uma proteção dos componentes eletrônicos contra fatores externos e uma segurança devido à alta potência, portanto, as imperfeições podem expor os componentes elétricos e gerar o risco de choque elétrico (LORENZO et al., 2020; TRIKI-LAHIANI; ABDELGHANI; SLAMA-BELKHODJA, 2018).

Falhas por arco elétrico um arco elétrico ocorre quando há uma ruptura dielétrica do ar, ou seja, um caminho de corrente elétrica é estabelecido através do ar. Essa situação pode ocorrer no interior dos módulos devido a danos no isolamento das células ou de forma externa pela corrosão dos conectores e cabos devido a ação de roedores ou pela abrasão na estrutura metálica. Ao contrário dos sistemas de corrente alternada, a corrente contínua não possui passagem periódica por zero e, portanto, é muito mais provável que um arco em uma instalação fotovoltaica resulte em um arco sustentado. Este tipo de falha é potencialmente perigosa, pois pode originar um incêndio no arranjo fotovoltaico (ALAM et al., 2015).

Queima de fusíveis as boas práticas recomendam que as séries fotovoltaicas sejam instaladas com um dispositivo para proteção de sobrecorrente, geralmente um fusível. No entanto, em condições climáticas específicas, a corrente da série pode exceder a corrente nominal do fusível e queimá-lo. Além disso, devido a mudanças climáticas repentinas, a variação do céu nublado para céu aberto, pode produzir sobrecorrentes de curta duração, mas capazes de gerar um estresse térmico e ocasionar a queima do fusível (LORENZO et al., 2020).

Descargas atmosféricas as usinas fotovoltaicas são altamente suscetíveis a descargas atmosféricas devido a quantidade de componentes metálicos e a sua grande extensão territorial. As descargas atmosféricas liberam uma elevada quantidade de energia que pode causar danos severos aos inversores e aos demais componentes elétricos e eletrônicos da usina e, em alguns casos, as estruturas mecânicas também podem ser afetadas. Inclusive, até mesmo em situações onde o ponto de impacto dos raios está a quilômetros de distância podem ocorrer avarias na usina devido aos surtos de tensão induzida no sistema de distribuição (LORENZO et al., 2020).

Falhas no aterramento problemas com o aterramento são típicos de instalações fotovoltaicas. As instalações possuem peças metálicas que podem conduzir eletricidade, como a estrutura para fixação dos módulos, a própria moldura dos módulos, os gabinetes dos painéis elétricos, etc. Durante a operação normal, estes dispositivos estão aterrados e não conduzem eletricidade, mas o referencial de terra pode ser perdido devido a falhas, o que acarreta no risco de choque elétrico. A queda na resistência de isolamento pode ser causada por uma série de situações, como: derretimento de materiais isolantes, corrosão, abrasão, infiltrações em dutos que fazem com que os cabos enterrados fiquem imersos na água, etc. (KHALIL et al., 2020; LORENZO et al., 2020).

Falhas no inversor FV os inversores possuem uma vida útil limitada e o envelhecimento destes dispositivos implica no desgaste de seus componentes eletrônicos, o que aumenta a probabilidade de falhas. Em geral, as falhas nos inversores podem ser classificadas em três categorias, sendo elas: i) problemas de fabricação que normalmente estão associados ao mau gerenciamento térmico; ii) problemas de controle relacionados à conversão da energia; iii) falhas nos componentes eletrônicos. Além disso, os inversores são equipados com um algoritmo responsável por ajustar continuamente a impedância percebida pelos módulos e manter o sistema operando no ponto que permite extrair a máxima potência. Apesar de alguns algoritmos não serem capazes de seguir o ponto de máxima potência instantaneamente, essa perda normalmente é muito baixa, inferior a 0,5% (TRIKI-LAHIANI; ABDELGHANI; SLAMA-BELKHODJA, 2018; STEIN, 2017).

A ocorrência desses fatores de degradação também está diretamente relacionada com o ambiente circundante a matriz fotovoltaica. Por exemplo, alguns estudos apontam que módulos fotovoltaicos instalados em climas quentes e úmidos apresentam maior degradação do que aqueles instalados em climas desérticos (LILLO-BRAVO et al., 2018).

Ao final dessa análise, percebe-se que as instalações fotovoltaicas estão suscetíveis a uma série de fatores que podem degradar a geração. Logo, o uso de ferramentas para o monitoramento contínuo e o diagnóstico da geração torna-se essencial para garantir a operação adequada da planta e, conseqüentemente, a extração da máxima potência.

2.2 MEDIÇÕES EM ARRANJOS FOTOVOLTAICOS

O monitoramento fotovoltaico comumente exige a aquisição de parâmetros elétricos e climáticos nas instalações fotovoltaicas. As medições realizadas em campo devem seguir uma metodologia adequada para que as informações mensuradas sejam válidas e possam ser aplicadas na avaliação de desempenho da instalação. Recomenda-se a aplicação da Norma IEC 61724-1 que aborda os equipamentos, os métodos e a terminologia para o monitoramento e análise de desempenho de instalações fotovoltaicas.

A IEC 61724-1 determina os tipos de sensores, a precisão, a taxa de aquisição, o processo de instalação e o condicionamento dos sinais monitorados. Além disso, a norma estabelece três classificações para o sistema de monitoramento que podem ser referenciadas por seu código de letras (A, B, C) ou por seu nome (alta precisão, média precisão, baixa precisão). Tanto a classe A como a classe B são indicadas para sistemas fotovoltaicos de grande porte, como as usinas.

O traçador de curvas I-V proposto neste trabalho exige a aquisição de parâmetros elétricos (tensão e corrente) e climáticos (irradiância e temperatura). Portanto, a seguir, são apresentadas algumas recomendações para a execução destas medições, assim como são discutidas algumas técnicas para os processos de amostragem e armazenamento dos dados. Ao final desta seção é explanada a importância da análise do impacto das incertezas das medições.

2.2.1 Medição de parâmetros elétricos

Os sistemas de monitoramento fotovoltaico frequentemente mensuram a corrente, a tensão e a potência, em corrente contínua e alternada. A Norma IEC 61724-1 estabelece que os dispositivos utilizados nas medições elétricas tenham a capacidade de realizar medições em uma faixa superior à 120% da saída esperada para situações onde o arranjo fotovoltaico está operando na STC. As medições classe A devem ser realizadas com a incerteza de $\pm 2,0\%$ para medições correspondentes à 20% ou superior da saída esperada para matriz operando na STC. Enquanto a classe B aplica-se apenas a medições em corrente alternada e exige uma precisão de $\pm 3,0\%$.

Algumas soluções para o monitoramento fotovoltaico utilizam os parâmetros elétricos mensurados pelo próprio inversor. No entanto, deve-se ressaltar que, muitas vezes, as medições realizadas pelos inversores não são especificadas pelos fabricantes e podem ser de baixa qualidade. Por exemplo, a quantidade de energia gerada informada pelos inversores pode divergir substancialmente dos valores registrados pelo medidor de energia da concessionária (CHIANTORE; PAPAECONOMOU; DEGENER, 2018).

2.2.2 Medição da irradiância incidente sobre os módulos

A irradiância é a quantificação da energia que entra no arranjo fotovoltaico e, portanto, deve ser mensurada com a mesma importância que a energia que sai do arranjo fotovoltaico, a potência elétrica. No entanto, a irradiância é muito mais difícil de medir com precisão e consistência, daí a necessidade de procedimentos regulamentados e o uso dos melhores instrumentos possíveis (FRIESEN et al., 2018).

A medição da irradiância pode ser realizada através das seguintes tecnologias:

Piranômetros dispositivos que permitem medir todo o espectro da radiação solar, o que pode causar uma divergência de até 3% com a irradiância absorvida pelos módulos fotovoltaicos, pois estes respondem em apenas uma região do espectro solar. Os piranômetros operam com base no efeito termoeletrico, o que implica em um maior tempo de resposta - cerca de 3 segundos a 5 segundos são necessários para atingir 95% do valor de uma mudança repentina

na irradiância. Por outro lado, as células de referência respondem quase instantaneamente (PHOTOVOLTAIC. . . , 2017; FRIESEN et al., 2018).

Células de referência são instrumentos construídos com o mesmo material dos módulos fotovoltaicos, o que correlaciona a irradiação medida com a absorvida pelos módulos. O uso destes dispositivos para a medição da irradiância é possível devido a proporcionalidade entre a corrente de curto-circuito das células de referência com a irradiação solar. A Norma IEC 60904-2 define os requisitos de classificação, calibração e manutenção das células fotovoltaicas. Devido aos dispositivos fotovoltaicos responderem em apenas uma região do espectro solar, deve-se optar por células de referência que possuam a mesma tecnologia dos módulos que compõem o arranjo fotovoltaico. Caso contrário, será necessário realizar a correção da incompatibilidade espectral, conforme especificado pela Norma IEC 60904-7. Por fim, destaca-se que a corrente de curto-circuito das células aumenta com a temperatura, o que implica na necessidade de medir a temperatura da célula e realizar a devida correção (FRIESEN et al., 2018).

Fotodiodos destacam-se pelo baixo custo em comparação com os piranômetros e as células de referência, mas geralmente são dispositivos com menor precisão. O uso de fotodiodos é recomendado para sistemas fotovoltaicos pequenos, ou então, onde não exige-se grande precisão.

Em geral, os piranômetros são empregados na medição da irradiância global, enquanto as células de referências são aplicadas na medição da irradiância no plano inclinado. A aceitabilidade universal como padrão para medições históricas e meteorológicas da irradiância favorece os piranômetros (KHALID et al., 2016).

A Norma IEC 61724-1 determina que a medição classe A deve ser realizada com piranômetros ou células de referência que possuam grau de incerteza inferior a $\pm 3,0\%$. No caso de incertezas de até $\pm 8,0\%$, a medição é classificada como classe B. As medições classe A e B não contemplam o uso de fotodiodos. O sistema de monitoramento deve ser capaz de medir a irradiância em uma faixa de 0 W/m^2 a 1.500 W/m^2 com uma resolução de pelo menos 1 W/m^2 . A irradiância acima de 1.000 W/m^2 pode ocorrer devido a reflexões nas nuvens quando o céu está parcialmente nublado (PHOTOVOLTAIC. . . , 2017).

A irradiância deve ser medida em um local representativo das condições do sistema. Se os módulos estiverem no sol e o sensor de irradiância na sombra, ou vice-versa, não haverá concordância entre o desempenho medido e o esperado. Logo, os sensores devem ser montados em uma área com visão aberta do céu, livre de irradiância refletida. Em casos de matrizes fotovoltaicas que ocupam uma grande área sugere-se o uso de mais de um sensor, os quais devem ser montados no plano da matriz. No caso de diferentes orientações dos módulos é necessário, pelo menos, um sensor para cada orientação. O alinhamento entre o sensor e os módulos deve ser inferior a 1° e $1,5^\circ$ para medições classe A e B, respectivamente. Os sensores de irradiância

devem ser limpos regularmente, assim como as calibrações devem ser realizadas periodicamente (FRIESEN et al., 2018).

2.2.3 Medição da temperatura de operação dos módulos

O aumento de temperatura dos módulos fotovoltaicos reduz a eficiência destes dispositivos e pode ser considerado um dos fatores de maior perda de energia. Logo, a medição correta da temperatura de operação dos módulos é fundamental para avaliar o desempenho de instalações fotovoltaicas. Em geral, a medição da temperatura é realizada através de métodos de medição por contato (sensor de temperatura fixado ao módulo). Entretanto, podem ser utilizados outros métodos, como a medição sem contato (usando câmera infravermelha) ou através da medição indireta (análise da tensão de circuito aberto de um dispositivo de referência). A medição por contato tornou-se a mais popular por ser relativamente simples, apresentar boa precisão e ter baixo custo de implementação (FRIESEN et al., 2018).

Os sensores de temperatura mais utilizados são as termorresistências e os termopares. As termorresistências possuem maior precisão, melhores características de estabilidade e repetibilidade, além de possuírem uma curva quase linear para a relação resistência por temperatura. Por outro lado, os termopares são mais baratos, são mecanicamente mais fortes e possuem menor tempo de resposta se comparado com as termorresistências (BEGA, 2011).

A medição por contato exige cuidados ao fixar o sensor no módulo. Recomenda-se que o sensor seja fixado com um adesivo apropriado para o uso externo prolongado, suporte as condições climáticas do local, seja compatível com o material do módulo e termicamente condutor. As fitas adesivas comuns ou fitas isolantes podem ceder sob condições de alta temperatura formando um espaço de ar entre o sensor e a traseira do módulo fotovoltaico, o que implica em um grande erro de medição (CUNNINGHAM; HERNDAY; MOKRI, 2014).

Um módulo fotovoltaico em operação não possui uma distribuição uniforme de temperatura, as bordas e a parte inferior do módulo são mais frias do que o centro e a borda superior. Logo, o sensor deve ser posicionado na parte traseira do módulo, próximo do meio, no centro de uma célula e afastado da caixa de junção do módulo. O posicionamento correto do sensor possibilita a medição da temperatura média do módulo (CHIANTORE; PAPAECONOMOU; DEGENER, 2018).

A temperatura dos módulos também pode ser verificada pela medição indireta. As células fotovoltaicas possuem como característica a proporcionalidade entre a tensão de circuito aberto e a temperatura de operação. Portanto, ao medir a tensão de circuito aberto é possível estimar a temperatura do módulo. A vantagem deste método está na possibilidade de medir a temperatura média do módulo, compensando a não uniformidade da temperatura. A desvantagem se dá pela necessidade de um módulo de referência adicional, não conectado na matriz fotovoltaica, para fins de medição de temperatura. A Norma IEC 60904-5 regulamenta o uso da tensão de circuito aberto para a medição da temperatura (PHOTOVOLTAIC..., 2017).

De acordo com a IEC 61724-1, a medição da temperatura dos módulos, incluindo o

condicionamento do sinal, deve ser realizada com grau de incerteza inferior à 2 °C. Assim como a irradiância, a temperatura deve ser medida em um local representativo, pois a temperatura pode ser afetada pela irradiância, a exposição ao vento, a estrutura de fixação e a tecnologia dos módulos. Assim sendo, em usinas de grande escala recomenda-se a instalação de uma quantidade maior de sensores para que se possa obter uma temperatura média do arranjo fotovoltaico. Salienta-se que a presença de ventos fortes soprando paralelamente às superfícies dos módulos pode introduzir uma diferença de temperatura superior à 5 °C (PHOTOVOLTAIC..., 2017).

2.2.4 Amostragem e armazenamento dos dados

A Norma IEC 61724-1 define o conceito de amostra como sendo os dados adquiridos por um sensor, o intervalo de amostragem como o tempo entre as aquisições e o registro como os dados que são armazenados em um determinado local. Os parâmetros registrados podem ser o valor médio, máximo, mínimo, a soma ou outra função das amostras adquiridas. No caso de medições classe A, a Norma IEC 61724-1 estabelece que os parâmetros elétricos e climáticos (irradiância e temperatura) sejam amostrados a cada 3 segundos e registrados a cada 1 minuto. Enquanto que, as medições da classe B exigem amostragem e registro a cada 1 e 15 minutos, respectivamente.

Os registros devem incluir a data e a hora correspondentes ao início ou ao final do intervalo e a escolha deve ser especificada. A hora deve referir-se à hora padrão local (não ao horário de verão) ou à hora universal. Quando existirem várias unidades de aquisição de dados, os relógios devem ser sincronizados, preferencialmente por um mecanismo automatizado (PHOTOVOLTAIC..., 2017).

A amostragem e os registros são realizados por dispositivos denominados de DAQ, do acrônimo, em inglês, *Data Acquisition System*, ou então, Sistema de Aquisição de Dados. O registro é um processo importante e deve ser confiável mesmo em situações extremas, como no caso de falhas na rede de comunicação ou de alimentação. O DAQ deve garantir a organização e a confiabilidade dos dados, além de uma operação autônoma, exigindo nenhuma ou mínima manutenção. Os DAQ diferenciam-se quanto ao intervalo de amostragem, os mecanismos de comunicação e registro, o software de interface com o usuário e a possibilidade de controlar o sistema fotovoltaico (CHIANTORE; PAPAECONOMOU; DEGENER, 2018).

Em relação aos protocolos de comunicação, um dos mais utilizados nas instalações fotovoltaicas é o Modbus. Em geral, opta-se pelo uso de um meio físico para a comunicação (*ethernet* ou RS-485), pois trata-se de uma solução confiável para a transmissão dos dados. No entanto, devido ao custo associado ao meio físico, alguns fabricantes optam por tecnologias sem fio, o protocolo ZigBee está se destacando pelo seu custo acessível e a capacidade de suportar uma grande quantidade de dispositivos na rede (TRIKI-LAHIANI; ABDELGHANI; SLAMA-BELKHODJA, 2018).

2.2.5 Impacto das incertezas das medições

Devido a expansão da geração fotovoltaica, o número de interessados que realizam medições em dispositivos fotovoltaicos está aumentando consideravelmente. Por exemplo, os fabricantes de módulos, os laboratórios de certificação, os pesquisadores, os investidores e outros segmentos publicam seus resultados em uma ampla variedade de mídias. No entanto, a comparabilidade dessas medidas é dificultada pela ausência de informações sobre as incertezas da medição (FRIESEN et al., 2018). Destaca-se que o resultado de uma medição é apenas uma aproximação do valor verdadeiro, a medição somente está completa quando acompanhada do valor da incerteza (GALLAS, 1998).

A falta de uma metodologia adequada para aquisição de dados pode fazer com que os módulos fotovoltaicos classificados como os “melhores” em um determinado estudo sejam considerados como “medíocres” em outros estudos. Além disso, os modelos fotovoltaicos, apesar de serem ótimas ferramentas para estimar com precisão a geração fotovoltaica, podem apresentar resultados insatisfatórios caso sejam treinados com dados de baixa qualidade. Portanto, a incerteza das medições tem um impacto direto na avaliação de desempenho das instalações fotovoltaicas e, conseqüentemente, no retorno financeiro dessas plantas (STEIN, 2017; RICHTER et al., 2015).


A confiabilidade das medições está sujeita as incertezas introduzidas pelos diferentes elementos da matriz fotovoltaica e não dependem apenas do sensor e do circuito de condicionamento. Por exemplo, ao medir a irradiância utilizando um instrumento ideal este produziria um sinal proporcional ao mensurado e não seria afetado por nenhum outro fator. No entanto, em instrumentos reais, a proporcionalidade do sinal pode mudar conforme a irradiância (não linearidade), a temperatura do corpo do sensor, a velocidade do vento, o ângulo de incidência, o período da medição e o espectro. Inclusive, geralmente ocorrem interações entre esses fatores que foram citados (REISE et al., 2018).

Nos últimos anos alguns trabalhos acadêmicos estão sendo publicados com o objetivo de discutir a importância da análise das incertezas em medições fotovoltaicas. Liu (2012) descreveu os procedimentos para o cálculo das incertezas correspondentes as medições em módulos fotovoltaicos. Dubard et al. (2014) apresentaram a metodologia e os níveis de incerteza que são alcançados pelos laboratórios e pela indústria fotovoltaica.

2.3 AQUISIÇÃO DE CURVAS I-V EM ARRANJOS FOTOVOLTAICOS

A curva I-V representa um conjunto de pares de pontos de operação de um módulo, uma série ou uma matriz fotovoltaica em uma dada condição de irradiância solar e temperatura, conforme mostra a Figura 7. Através da curva I-V podem ser obtidos alguns pontos de interesse para o diagnóstico da geração, são eles: a tensão de circuito aberto (V_{oc}), a corrente de curto-circuito (I_{sc}), a tensão no ponto de máxima potência (V_{mp}), a corrente no ponto de máxima potência (I_{mp}) e a potência máxima (P_{mp}).

Figura 7 – Exemplo de uma curva I-V típica.

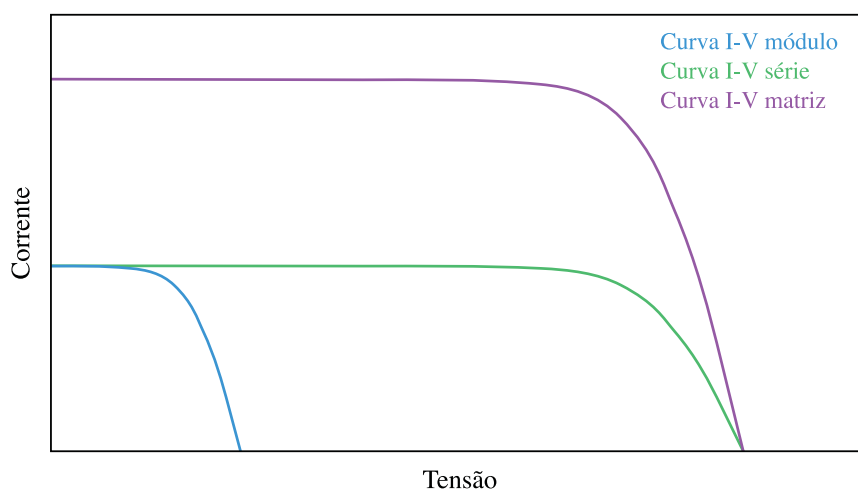


Fonte: Elaborada pelo autor (2019).

A tensão de circuito aberto é a tensão máxima em uma curva I-V. Enquanto que a corrente de curto-circuito é a corrente máxima em uma curva I-V, essa situação corresponde a uma condição de curto-circuito, pois as células fotovoltaicas são inerentemente limitadas em corrente. A potência máxima é o ponto de operação em que o produto entre a corrente e a tensão atinge o valor máximo. Esse ponto está localizado no “joelho” da curva I-V e representa o ponto de operação de maior eficiência. A tensão no ponto de máxima potência corresponde a cerca de 70% a 80% de V_{oc} e a corrente no ponto de máxima potência corresponde a aproximadamente 90% de I_{sc} (SEAWARD, 2012).

Em uma matriz fotovoltaica, a quantidade de módulos conectados em série determina a tensão da matriz, já a quantidade de séries fotovoltaicas conectadas em paralelo determina a corrente da matriz. Logo, a curva I-V de uma série fotovoltaica é formada pela soma das curvas de cada um dos módulos, enquanto a curva da matriz é formada pela soma das curvas das séries FV, conforme mostra a Figura 8.

Figura 8 – Composição da curva I-V de uma matriz fotovoltaica.



Fonte: Adaptado de Herrmann et al. (2021b).

A aquisição de curvas I-V trata-se de um ensaio que exige o uso de uma metodologia adequada para que os parâmetros mensurados possam ser aplicados na avaliação de desempenho de instalações fotovoltaicas. As Normas IEC 61724-1, IEC 62446-1 e IEC 60904-1 estabelecem as principais diretrizes para este ensaio. A IEC 61724-1, já abordada na Seção 2.2 deste trabalho, estabelece os equipamentos e os métodos para o monitoramento de instalações fotovoltaicas.

A Norma IEC 62446-1 especifica duas categorias de testes para a inspeção e comissionamento de sistemas fotovoltaicos. O ensaio da curva I-V é contemplado pela segunda categoria, portanto, destina-se a sistemas maiores ou mais complexos. De acordo com a norma, o ensaio deve ser realizado em condições estáveis de irradiância e com pelo menos 400 W/m^2 medido no plano do arranjo. No caso de matrizes com séries fotovoltaicas idênticas, as curvas podem ser comparadas (sobrepostas), sendo que elas não devem divergir além de 10% para condições estáveis de irradiância e temperatura. No caso de condições climáticas instáveis, as curvas I-V podem ser convertidas para uma condição comum de irradiância e temperatura para posteriormente serem sobrepostas.

A Norma IEC 60904-1 descreve os procedimentos para a medição da curva I-V de módulos fotovoltaicos com o objetivo de caracterizar estes dispositivos. De acordo com a norma, a irradiância solar global não deve flutuar além de $\pm 1\%$ durante o ensaio. Destaca-se que se a curva I-V for adquirida em períodos de instabilidade da irradiância, qualquer atraso entre a aquisição da curva I-V e a medição da irradiância se traduz em um erro aleatório de medição. Assim sendo, sugere-se a medição da irradiância antes e após a aquisição da curva I-V para assegurar que não houve uma alteração significativa da irradiância durante o ensaio. No caso de conversão das curvas I-V para a condição padrão de testes, a norma estabelece que o ensaio deve ser realizado com a irradiância mínima de 800 W/m^2 .

A posição do Sol em relação à orientação da matriz é um fator importante na qualidade do ensaio. Recomenda-se que durante a aquisição da curva I-V, a posição dos módulos fotovoltaicos seja perpendicular ao feixe solar, dentro de $\pm 5^\circ$. Quando a irradiância atinge o módulo com um ângulo de 90° , maior quantidade de luz é transmitida através do vidro para as células se comparado aos instantes em que a irradiância atinge as células em ângulos oblíquos. Uma prática comum é realizar o ensaio dentro de 2 a 3 horas do meio dia solar. (CUNNINGHAM; HERNDAY; MOKRI, 2014).

A medição da irradiância, de acordo com a IEC 60904-1, deve ser realizada através de uma célula de referência ou um piranômetro, sendo que este dispositivo deve estar montado de forma coplanar aos módulos fotovoltaicos ($\pm 2^\circ$). A temperatura dos módulos deve permanecer estável dentro de $\pm 1^\circ \text{C}$ durante o ensaio, ser adquirida com a precisão de $\pm 1^\circ \text{C}$ e com a repetibilidade de $\pm 0,5^\circ \text{C}$. A tensão e a corrente devem ser mensuradas com precisão de $\pm 0,2\%$ da tensão de circuito aberto e da corrente de curto-circuito, respectivamente. A corrente de curto-circuito deve ser medida no ponto de tensão zero ou pode ser extrapolada, desde que o ponto de menor tensão aferido não seja superior a 3% da tensão de circuito aberto.

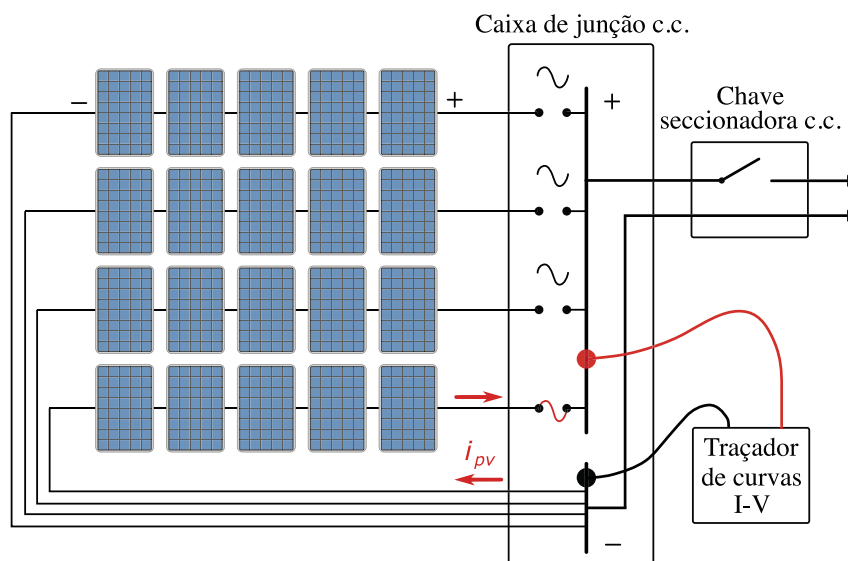
A quantidade mínima de pontos que formam a curva I-V não é especificada pelas normas e varia conforme o projeto do traçador de curvas. Em geral, as curvas possuem de 20 até 500 pontos. A velocidade de varredura pode impactar significativamente na medição, sendo que a maioria dos traçadores realizam a aquisição em um intervalo de 0,05 a 3 segundos. Este período é considerado um bom compromisso com as tecnologias de módulos que possuem resposta lenta e as condições climáticas que variam abruptamente (FRIESEN et al., 2018).

Para Spertino et al. (2015), a aquisição da curva I-V deve ocorrer, preferencialmente, em um intervalo de tempo superior a 20 ms e inferior a 100 ms. Apesar de valores heurísticos, justifica-se o limite superior pela necessidade de evitar que o clima, principalmente a irradiância, influencie nas medições. Já o limite inferior é justificado devido às oscilações transitórias que ocorrem ao iniciar a aquisição da curva I-V. Esse comportamento dinâmico é causado por parâmetros parasitas presentes no arranjo fotovoltaico, como a capacitância provocada pelas conexões série/paralela entre os módulos e a indutância devido ao comprimento dos cabos.

O passo a passo para a medição manual da curva I-V de uma série fotovoltaica foi estabelecido por Cunningham, Hernday e Mokri (2014). De acordo com os autores e com base na Figura 9, os passos a serem seguidos são os seguintes:

1. Desligue o inversor fotovoltaico (se exigido pela política de operação e manutenção da instalação FV);
2. Abra a chave seccionadora da caixa de junção na qual as medições das curvas I-V serão realizadas;
3. Levante todos os fusíveis das séries fotovoltaicas;
4. Conecte os cabos de teste do traçador de curvas I-V aos barramentos positivo e negativo, observando as polaridades;
5. Selecione uma série fotovoltaica inserindo seu fusível;
6. Faça a medição da curva I-V;
7. Inspeccione os resultados, se necessário, repita a medição;
8. Salve os resultados;
9. Levante o fusível da série fotovoltaica;
10. Repita a sequência para cada série restante na caixa de junção.

Figura 9 – Configuração para medir a curva I-V de séries fotovoltaicas em uma caixa de junção.



Fonte: Adaptado de Cunningham, Hernday e Mokri (2014).


2.3.1 Métodos para aquisição experimental da curva I-V

Os primeiros rastreadores de curvas foram desenvolvidos na década de 1950 para caracterizar o desempenho de componentes eletrônicos como os tubos de vácuo, transistores e diodos. Posteriormente, estes equipamentos foram adaptados para rastrear as curvas I-V de arranjos fotovoltaicos (CUNNINGHAM; HERNDAY; MOKRI, 2014). Uma das primeiras pesquisas na área dos traçadores de curvas aplicado a dispositivos fotovoltaicos foi desenvolvida por Warner e III (1982). Atualmente, existe uma série de métodos que podem ser aplicados no rastreamento de curvas I-V, sendo que eles variam quanto à forma de operação, precisão, facilidade de implementação e custos. Os principais métodos para aquisição de curvas I-V são:

Método da resistência variável teoricamente é a forma mais simples de rastrear a curva I-V. O método consiste em conectar uma carga resistiva em paralelo com o módulo fotovoltaico e incrementar o valor da resistência de zero até infinito, conforme mostra a Figura 10. A cada incremento no valor da resistência, os valores de tensão e corrente, fornecidos pelo gerador fotovoltaico, devem ser amostrados e armazenados (DURAN et al., 2008).

Uma vantagem deste método está na possibilidade de ser automatizado através de um sistema com relés que possibilita a escolha da combinação desejada de resistores. As desvantagens ficam por conta da incapacidade de medir o valor exato da corrente de curto-circuito, a limitação da quantidade de pontos da curva I-V (depende da combinação dos resistores disponíveis) e a restrição ao uso em geradores FV de baixa potência (exige resistores para potências elevadas). Consequentemente, na prática, mostra-se um método trabalhoso, impreciso e rígido. Na literatura alguns trabalhos implementaram esse método, como os desenvolvidos por Gupta, Chauhan e Saxena (2016) e Rivai e Rahim (2014).


Figura 10 – Método da resistência variável para rastrear a curva I-V.



Fonte: Elaborada pelo autor (2018).

Método da carga capacitiva consiste em conectar um capacitor em paralelo com o módulo fotovoltaico, conforme mostra a Figura 11. Enquanto o capacitor é carregado (S_1 fechado e S_2 aberto), o circuito move-se do ponto de curto-circuito para o ponto de circuito aberto. O capacitor, quando descarregado, comporta-se como um curto-circuito e à medida que vai sendo carregado, a corrente diminui e a tensão aumenta até atingir a condição de circuito aberto. Logo, os capacitores emulam o comportamento de um resistor variável. Antes de iniciar uma nova medição, o capacitor deve ser descarregado (S_1 aberto e S_2 fechado) (DURAN et al., 2008). Na prática, para melhorar a precisão da medição de tensão, recomenda-se que o sensor seja deslocado para a esquerda do transistor S_1 .

Figura 11 – Método da carga capacitiva para rastrear a curva I-V.



Fonte: Elaborada pelo autor (2018).

Os capacitores consomem pouca energia e apresentam uma ondulação desprezível na medição dos parâmetros elétricos de curvas I-V. Trata-se de um método confiável e seguro, sendo utilizado pela maioria dos traçadores comerciais. Uma desvantagem deste método está no alto custo dos capacitores eletrolíticos que possuem baixa resistência série equivalente. Além disso, no caso de sistemas de alta potência, os capacitores tornam-se grandes e volumosos (SAYYAD; NASIKKAR, 2021).

O projeto do traçador de curvas deve considerar que a capacitância é diretamente proporcional à corrente de curto-circuito dos módulos fotovoltaicos e inversamente proporcional à tensão de circuito aberto. De acordo com Warner e III (1982), a capacitância pode ser dimensionada por:

$$C = \frac{I_{sc}}{V_{oc}} \cdot T_{car} \quad (1)$$

onde C é o valor da capacitância, I_{sc} é a corrente de curto-circuito, V_{oc} é a tensão de circuito aberto e T_{car} é o período, em segundos, para a carga capacitiva ser carregada.

Por outro lado, após a aquisição de uma curva I-V, a carga capacitiva deve ser descarregada antes que um novo ensaio seja realizado. O tempo mínimo necessário para descarregar a carga capacitiva com segurança, de acordo com Sayyad e Nasikkar (2021), é dado por:

$$T_{des} = 5 \cdot R \cdot C \quad (2)$$

onde T_{des} é o período para descarregar a carga capacitiva e R é a resistência de descarga.


Muitos autores já investigaram o método da carga capacitiva e obtiveram resultados positivos em suas pesquisas. Ibirriaga et al. (2010) projetaram um banco de capacitores que permite medir a curva I-V sempre com o mesmo intervalo de tempo, mesmo em situações de baixa irradiância. Erkaya, Moses e Marsillac (2016) investigaram e concluíram que o valor da capacitância tem influência apenas sobre o período da medição, pois a qualidade da curva I-V mostrou-se constante independente da capacitância.

Alguns autores recomendam que o capacitor seja carregado com tensão negativa. Essa técnica é utilizada para garantir que os pontos próximos da corrente de curto-circuito sejam mensurados. Por outro lado, muitas vezes, a técnica da carga negativa é substituída pela extrapolação matemática de I_{sc} . Por exemplo, no caso do dispositivo desenvolvido por Erkaya, Moses e Marsillac (2016), a prioridade está no tamanho do traçador, o que inviabiliza a presença de um circuito para realizar a carga negativa.

Método da carga eletrônica transistores de potência como MOSFET ou IGBT, por exemplo, podem ser utilizados como carga eletrônica na aquisição de curvas I-V, conforme mostra a Figura 12. Os transistores devem operar nas regiões de corte, ativa e de saturação. Um MOSFET operando na região ativa emula um resistor variável, onde a resistência entre o coletor e o emissor varia conforme a tensão aplicada entre a base e o emissor.

A vantagem deste método está em seu tamanho reduzido, no controle da velocidade de aquisição e na possibilidade de varrer a curva I-V em qualquer direção - de circuito aberto a curto-circuito e vice-versa. A desvantagem está na necessidade de dissipar níveis elevados de potência, dado que a potência do dispositivo fotovoltaico é dissipada pelo transistor. O uso de vários transistores agrupados em série e/ou em paralelo é uma solução para a dissipação de potências mais elevadas. Além disso, a carga eletrônica apresenta um valor finito de resistência na região de saturação, o que resulta em medições errôneas próximas de I_{sc} (SAYYAD; NASIKKAR, 2021).

Figura 12 – Método da carga eletrônica para rastrear a curva I-V.




Fonte: Elaborada pelo autor (2018).

O uso de MOSFET como carga eletrônica foi investigado por Taciuc (2016), enquanto que o uso de IGBT foi examinado por Saini et al. (2016). Ambas as pesquisas apresentam resultados satisfatórios na aquisição de curvas I-V de geradores fotovoltaicos.

Conversor c.c.-c.c. são dispositivos que possuem a capacidade de emular um resistor variável, cujo valor da resistência é proporcional a razão cíclica do conversor (DURAN et al., 2008). A Figura 13 mostra a topologia de um conversor SEPIC aplicado no rastreamento da curva I-V de um módulo fotovoltaico.

Figura 13 – Conversor c.c.-c.c. com topologia SEPIC para o rastreamento de curvas I-V.



Fonte: Elaborada pelo autor (2018).

As topologias consideradas clássicas, como Buck, Boost e Buck-Boost também podem ser utilizadas no rastreamento de curvas I-V. No entanto, o conversor Buck não pode emular impedâncias menores que a impedância de carga, o que implica na impossibilidade de rastrear os pontos próximos de I_{sc} . Já o conversor Boost não pode emular impedâncias maiores que a impedância de carga e, portanto, não pode rastrear os pontos próximos de V_{oc} . Em compensação, o conversor Buck-Boost e as suas topologias derivadas permitem varrer toda a curva I-V (DURAN et al., 2008).

As topologias Buck-Boost e Zeta possuem como característica a corrente elétrica pulsada na entrada do conversor, o que causa problemas significativos para a aquisição de curvas I-V. Por outro lado, as topologias Ćuk e SEPIC possuem a corrente de entrada com baixa ondulação, tornando-as adequadas para a aquisição de curvas I-V. Tanto o conversor Ćuk como o SEPIC possuem o mesmo número de componentes, submetem os transistores aos

mesmos esforços e possuem níveis de eficiência similares. No entanto, o conversor SEPIC possui a não-inversão da polaridade na tensão de saída e pode ser facilmente projetado com isolamento galvânica (DURAN et al., 2007).

Uma vantagem do uso de conversores c.c.-c.c., assim como ocorre no método da carga eletrônica, está na possibilidade de varrer a curva I-V em qualquer direção e controlar a velocidade de aquisição. No entanto, este método demanda de um tempo maior para completar a varredura da curva I-V, o que pode implicar em variações climáticas durante a aquisição. Além disso, controlar a razão cíclica acima de 80% pode não ser uma tarefa simples e implicar em erros na medição (SAYYAD; NASIKKAR, 2021).

Fonte de alimentação de quatro quadrantes trata-se de um instrumento que possui a característica de fornecer e dissipar energia. Logo, comporta-se como uma carga ajustável e pode ser utilizada no rastreamento de curvas I-V. A tensão e a corrente podem assumir valores positivos ou negativos, o que possibilita que a fonte de alimentação opere em todos os quatro quadrantes. Para um módulo fotovoltaico, o objetivo é obter a curva I-V no primeiro quadrante, porém os pontos situados no segundo e no quarto quadrantes permitem obter facilmente alguns pontos de interesse, como I_{sc} e a V_{oc} . Este é o método mais rápido e mais preciso para a aquisição de curvas I-V. No entanto, trata-se de um instrumento caro e volumoso. Portanto, atualmente, o uso das fontes de alimentação de quatro quadrantes está limitado a análises laboratoriais (DURAN et al., 2008; ZHU; XIAO, 2020).

Ao final dessa análise pode-se concluir que existem diferentes métodos para a aquisição de curvas I-V de módulos fotovoltaicos. Contudo, não existe uma solução que seja ótima para todos os casos, cada uma possui as suas vantagens e desvantagens. A potência do dispositivo fotovoltaico, a precisão da aquisição e a aplicação na qual se destina o traçador de curvas I-V são características que auxiliam na escolha do método mais adequado para o rastreamento.

2.3.2 Soluções comerciais para aquisição de curvas I-V

A pesquisa acadêmica na área dos traçadores de curvas I-V permitiu o desenvolvimento de equipamentos comerciais e estes já foram amplamente adotados para o comissionamento e monitoramento de usinas fotovoltaicas. A especificação desses equipamentos se dá, geralmente, pela precisão e pela faixa de medição dos parâmetros elétricos. A Tabela 4 apresenta uma síntese das principais soluções comerciais para a aquisição de curvas I-V.

Alguns dispositivos já integram os sensores para medição da irradiância e da temperatura, esse é o caso dos equipamentos desenvolvidos pela Chauvin Arnoux, HT Instruments, Pv Engineering, Seaward e Solmetric. Por outro lado, alguns dispositivos possuem interfaces para conexão de sensores externos. Vale destacar que a medição dos parâmetros climáticos é essencial para a análise das curvas I-V.

Tabela 4 – Soluções comerciais para a aquisição de curvas I-V

Fabricante / modelo	Faixa de medição	Precisão (tensão / corrente)
Chauvin Arnoux / FTV 200	1000 V, 10 A	Não informado
Daystar / DS-1000	1000 V, 100 A	$\pm 0,4$ V $\pm 0,01\%$ / ± 50 mA $\pm 0,05\%$
EKO Instruments / MP-11	1000 V, 30 A	$\pm 1,0\%$ / $\pm 1,0\%$
Fluke / SMFT-1000	1000 V, 20 A	$\pm 0,5\%$ / $\pm 1,0\%$
HT Instruments / I-V 500W	1500 V, 15 A	$\pm 0,5\%$ / $\pm 1,0\%$
Pordis / 140A-III	1000 V, 15 A	Não informado
Pv Engineering / PVPM1500X	1500 V, 20 A	$\pm 1,0\%$ / $\pm 1,0\%$
Seaward / PV200	1000 V, 15 A	$\pm 0,5\%$ / $\pm 1,0\%$
Solmetric / PVA-1500V4	1500 V, 30 A	$\pm 0,25$ V $\pm 0,5\%$ / ± 40 mA $\pm 0,5\%$

Fonte: Adaptado de Sayyad e Nasikkar (2021).

Em geral, a maioria dos equipamentos comerciais são portáteis e necessitam de um operador para realizar manualmente a aquisição das curvas I-V. Dentre os equipamentos citados, a exceção está no traçador 140A Series III produzido pela Pordis. Trata-se de um dispositivo integrado a usinas e que permite o rastreamento automático de curvas I-V de séries fotovoltaicas individuais. O 140A é semelhante ao traçador de curvas proposto neste trabalho, mas diferencia-se pela ausência de uma metodologia integrada para diagnóstico da geração fotovoltaica.

2.3.3 Conversão da curva I-V para o STC

As condições climáticas, conforme já apresentado neste trabalho, afetam o desempenho das instalações fotovoltaicas e essa situação pode dificultar o processo de monitoramento. Por exemplo, uma usina que possui a potência nominal de 500 kW deverá apresentar uma potência de aproximadamente 350 kW se a irradiância solar for de 700 W/m², assumindo a temperatura de 25 °C. No entanto, essa análise pode ser simplificada se os parâmetros elétricos aferidos em uma dada condição climática forem convertidos para uma condição padrão de irradiância e temperatura. Inclusive, o processo de conversão viabiliza que curvas I-V adquiridas sob distintas condições climáticas possam ser comparadas (sobrepostas).

Geralmente, os parâmetros elétricos são convertidos para a condição padrão de teste (STC, acrônimo para *Standard Test Conditions*), uma classificação universal para módulos fotovoltaicos. A STC especifica a saída elétrica para irradiância solar de 1.000 W/m², irradiância espectral solar denominada de massa de ar 1,5 (AM1,5) e temperatura da célula de 25 °C. O desempenho dos dispositivos fotovoltaicos também pode ser representado em outras condições climáticas, como o padrão americano denominado PTC, acrônimo para *PV-USA Test Conditions*, que representa uma condição mais próxima da operação no campo. O PTC estabelece a irradiância solar de 1.000 W/m², temperatura da célula de 45 °C e velocidade do vento de 1 m/s (SEAWARD, 2012).

Até o momento, não existe um método consolidado para a conversão de curvas I-V. Na literatura estão disponíveis alguns procedimentos que podem ser aplicados nesse processo, onde destaca-se o trabalho de Anderson (1996). O autor que tinha como objetivo desenvolver um método para prever o desempenho de dispositivos fotovoltaicos em uma ampla faixa de condições de temperatura e irradiância propôs um procedimento baseado nas seguintes equações:

$$I_{conv} = \frac{I_{med}}{\left[1 + \frac{\alpha_{I_{sc}}}{100} \cdot (T_{med} - T_{conv})\right]} \cdot \frac{G_{med}}{G_{conv}} \quad (3)$$

$$V_{conv} = \frac{V_{med}}{\left[1 + \frac{\beta_{V_{oc}}}{100} \cdot (T_{med} - T_{conv})\right] \cdot \left[1 + \delta \cdot \ln\left(\frac{G_{med}}{G_{conv}}\right)\right]} \quad (4)$$

onde o subscrito *med* identifica os parâmetros que foram medidos, enquanto *conv* identifica os parâmetros a serem convertidos, por exemplo, para a STC. O parâmetro G é a irradiância no plano da matriz e T a temperatura de operação dos módulos. $\alpha_{I_{sc}}$, $\beta_{V_{oc}}$ e γ_{mpp} são os coeficientes de temperatura definidos em porcentagem por grau Celsius. δ é um fator de correção da irradiância e depende da tecnologia do módulo fotovoltaico.

Além dos métodos que estão disponíveis na literatura, a Norma IEC 60891 estabelece quatro procedimentos para a conversão de curvas I-V. São eles:

Primeiro método trata-se do método de conversão indicado para as situações em que a irradiância da curva I-V mensurada não ultrapassa em $\pm 40\%$ da irradiância alvo. O método utiliza o seguinte sistema de equações:

$$I_{conv} = I_{med} + I_{sc_{med}} \cdot \left(\frac{G_{conv}}{G_{med}} - 1\right) + \frac{\alpha_{I_{sc}}}{100} \cdot (T_{conv} - T_{med}) \quad (5)$$

$$V_{conv} = V_{med} - R_s \cdot (I_{conv} - I_{med}) - \kappa \cdot I_{conv} \cdot (T_{conv} - T_{med}) + \frac{\beta_{V_{oc}}}{100} \cdot (T_{conv} - T_{med}) \quad (6)$$

onde R_s é a resistência série do dispositivo fotovoltaico e κ é um fator de correção da curva I-V.

Segundo método é um procedimento alternativo de correção algébrica e que produz melhores resultados para grandes correções de irradiância (acima de $\pm 40\%$). No entanto, esse método é baseado no modelo fotovoltaico de um diodo e contém seis parâmetros de correção que podem ser determinados pela medição de curvas I-V em diferentes condições de temperatura e irradiância. Além dos coeficientes de temperatura relativos para a corrente de curto-circuito e tensão de circuito aberto, um coeficiente de temperatura adicional é calculado para modelar a dinâmica da resistência interna dos geradores fotovoltaicos. Por fim, um fator quadrático da irradiância é estimado com o objetivo de representar o fator de idealidade do modelo fotovoltaico.

Terceiro método utiliza uma estratégia de interpolação e não requer parâmetros de correção, apenas duas curvas I-V. O procedimento é baseado nas seguintes equações:

$$I_{conv} = I_1 + \zeta \cdot (I_2 - I_1) \quad (7)$$

$$V_{conv} = V_1 + \zeta \cdot (V_2 - V_1) \quad (8)$$

onde (I_1, V_1) e (I_2, V_2) são as coordenadas de pontos da primeira e da segunda curva I-V. O parâmetro ζ é uma constante de interpolação que pode ser obtida através da relação entre a irradiância e a temperatura das duas curvas I-V. Destaca-se que esse terceiro método é indicado para a interpolação de curvas I-V, sendo que a extrapolação deve ser praticada com cautela.

Quarto método o último procedimento é baseado no modelo fotovoltaico de diodo único e permite a conversão de curvas I-V, a partir de uma única curva experimental. As equações a serem empregadas por esse método são as seguintes:

$$I_{conv} = I_{med} + I_{sc_{med}} \cdot \left(\frac{G_{conv}}{G_{med}} - 1 \right) + \alpha_{I_{sc}} \cdot I_{sc_{STC}} \cdot (T_{conv} - T_{med}) \quad (9)$$

$$V_{conv} = \left[V_{med} - R_s \cdot I_{sc_{med}} \cdot \left(\frac{G_{conv}}{G_{med}} - 1 \right) \right] \cdot \left[1 + \frac{T_{conv} - T_{med}}{T_{med}} \right] - \frac{T_{conv} - T_{med}}{T_{med}} \cdot n_s \cdot \varepsilon \quad (10)$$

onde n_s é a quantidade de células conectadas em série e ε é uma constante que depende do material do dispositivo fotovoltaico. Deve-se salientar que este procedimento é baseado no modelo de diodo único. Assim sendo, não deve ser aplicado a dispositivos que não seguem esse modelo, como é o caso dos módulos degradados ou parcialmente sombreados.

Aplicar os procedimentos de conversão estabelecidos pela Norma IEC 60891 não é uma tarefa trivial. Isso se dá pela dificuldade em calcular os fatores de correção. Por exemplo, para calcular o valor da resistência série (R_s) a norma exige um conjunto de curvas I-V medidas sob a mesma temperatura (tolerância de $\pm 0,5$ °C) e em diferentes níveis de irradiância. Assim como, o cálculo do fator de correção κ requer um conjunto de curvas I-V medidas sob a mesma irradiância (tolerância de $\pm 1\%$) e em diferentes temperaturas. Uma forma alternativa para determinar esses parâmetros de correção, através de uma quantidade reduzida de medições, foi proposta por Abe et al. (2020). No entanto, este método foi desenvolvido com base na versão de 2009 da Norma IEC 60891, a qual sofreu um processo de atualização em 2021 que implicou em modificações nas equações que são utilizadas na conversão das curvas I-V.

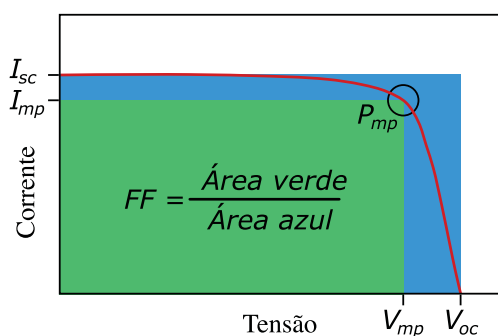
2.3.4 Análise da curva I-V

A sobreposição de curvas I-V de séries fotovoltaicas idênticas permite avaliar o desempenho de uma instalação fotovoltaica. De acordo com a Norma IEC 62446-1, as curvas I-V podem divergir em até 10% para condições estáveis de irradiância e temperatura. No entanto, a sobreposição de curvas não é a única maneira de avaliar o desempenho da instalação, o cálculo de indicadores, como o fator de forma, pode ser uma alternativa interessante.

O fator de forma (FF) é uma figura de mérito que expressa a capacidade do gerador fotovoltaico de produzir potência em relação a corrente de curto-circuito e a tensão de circuito aberto. A Figura 14 mostra que o FF pode ser determinado a partir da razão entre a área verde pela área azul do gráfico. O FF também pode ser calculado por:

$$FF = \frac{I_{mp} \cdot V_{mp}}{I_{sc} \cdot V_{oc}} \quad (11)$$

Figura 14 – Fator de forma de uma curva I-V.



Fonte: Adaptado de Cunningham, Hernday e Mokri (2014).

O fator de forma é uma excelente métrica para comparar o desempenho de um conjunto de séries fotovoltaicas, pois é relativamente independente da irradiância (para níveis de irradiância elevada) e pode ser calculado a partir de parâmetros da própria curva I-V. Vale salientar que uma parcela significativa dos fatores que degradam a geração fotovoltaica causam distorções no formato da curva I-V e podem ser identificados pela redução do FF (CUNNINGHAM; HERNDAY; MOKRI, 2014).

Além do fator de forma, uma outra métrica interessante para avaliar uma instalação fotovoltaica é o fator de desempenho (FD). Essa métrica descreve o quanto da potência máxima medida concorda com a potência estimada. O fator de desempenho pode ser definido por:

$$FD = \frac{P_{mp_{medida}}}{P_{mp_{estimada}}} \quad (12)$$

a potência máxima medida ($P_{mp_{medida}}$) é mensurada em campo, enquanto que a potência máxima estimada ($P_{mp_{estimada}}$) pode ser calculada através de um modelo matemático.

Existem outras métricas que podem ser úteis na avaliação de desempenho de instalações fotovoltaicas. Por exemplo, a razão entre a corrente no ponto de máxima potência e a corrente de curto-circuito (I_{mp}/I_{sc}) fornece uma análise da resistência paralela. Assim como, a razão entre a tensão no ponto de máxima potência e a tensão de circuito aberto (V_{mp}/V_{oc}) fornece uma análise da resistência série. Se o resultado dessas duas métricas se aproximarem do valor unitário, considera-se que o desempenho está adequado, caso contrário, é provável que algo esteja degradando a geração (JONES et al., 2018).

As métricas apresentadas contribuem para que o ensaio da curva I-V seja um meio de medir e avaliar o desempenho de instalações fotovoltaicas. De acordo com a Norma IEC 62446-1, o formato da curva I-V pode fornecer informações importantes sobre o dispositivo analisado e as seguintes situações podem ser identificadas:

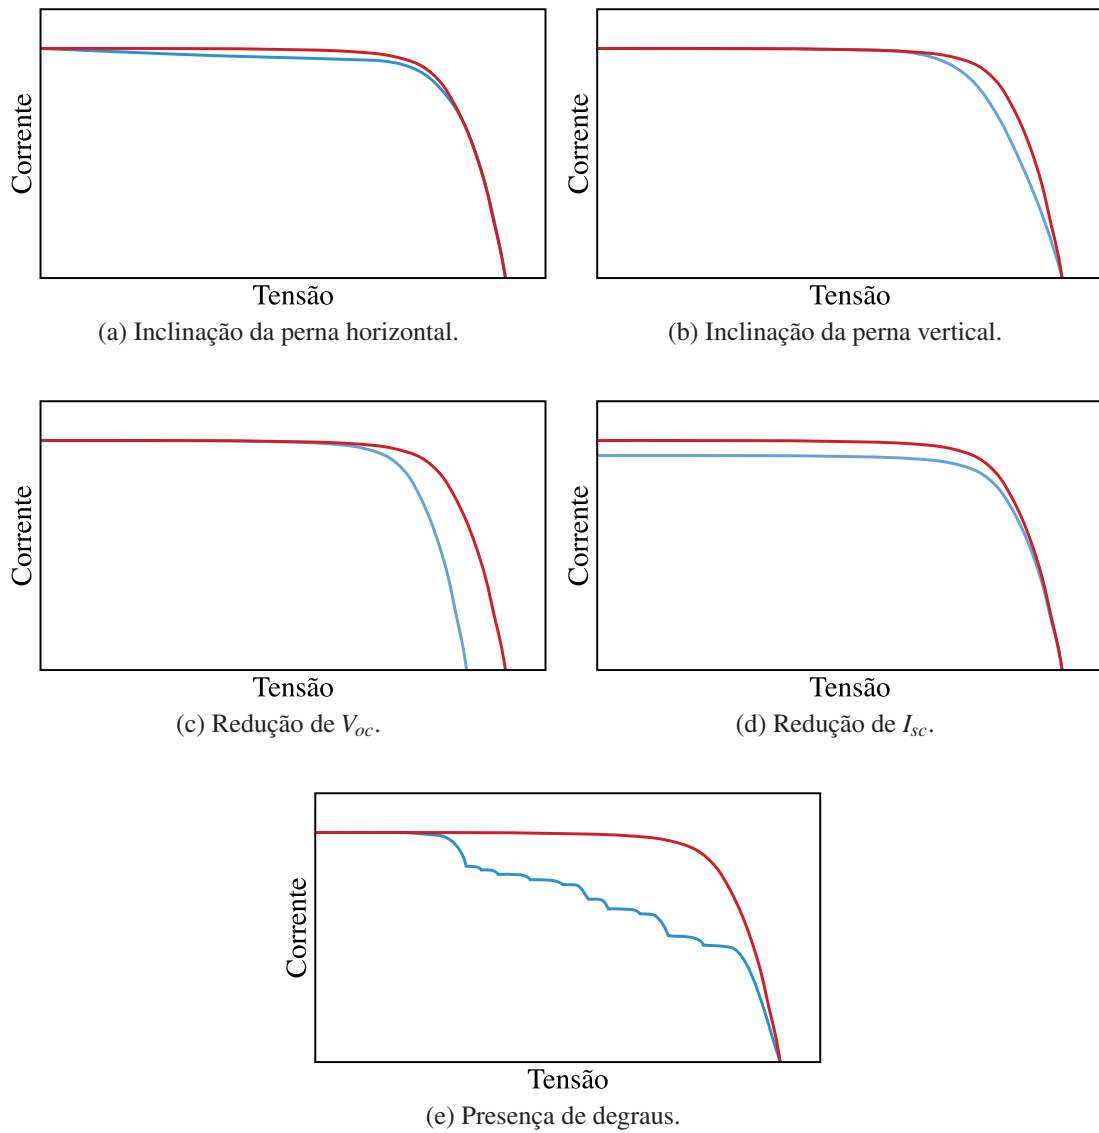
- Diodos de *by-pass* curto-circuitados;
- Incompatibilidade de módulos fotovoltaicos;
- Módulos danificados;
- Resistência paralela com valor baixo;
- Resistência série com valor elevado;
- Sombreamento parcial;
- Sujidade.

As curvas I-V podem apresentar alguns desvios que indicam uma redução de potência. Esses desvios podem ocorrer de maneira isolada ou podem ser ocasionados por uma combinação de fatores, o que pode tornar a interpretação muito complexa. Em geral, as principais diferenças que podem ser percebidas ao comparar uma curva I-V medida com uma curva ideal estão ilustradas pela Figura 15 e são as seguintes:

Inclinação da perna horizontal uma maior inclinação na perna horizontal da curva I-V está associada à redução da resistência em paralelo e representa fugas de corrente. Isso pode ocorrer devido a problemas de isolamento das células, incompatibilidade entre os módulos, fissuras nas células, sujidade, etc.

Inclinação da perna vertical uma menor inclinação na perna vertical ocorre devido ao aumento da resistência série. A situação pode ser originada por danos na fiação, cabos mal dimensionados, falhas nas soldas ou nas trilhas que interconectam as células FV, assim como falhas nas conexões entre os próprios módulos fotovoltaicos. Os defeitos relacionados com as conexões entre as células e os módulos podem ser causados por degradação, corrosão ou até problemas de fabricação. Vale ressaltar que ao ensaiar séries fotovoltaicas com cabos longos, a resistência desses cabos influenciará no formato da curva I-V.

Figura 15 – Principais tipos de desvios que podem ocorrer em curvas I-V.



Fonte: Adaptado de Jones et al. (2018).

Redução de V_{oc} a redução na tensão de circuito aberto pode ocorrer devido ao sombreamento significativo e uniforme de todo o arranjo fotovoltaico, ou então, pela presença de diodos de *by-pass* curto-circuitados. Os diodos são dispositivos eletrônicos que podem ser danificados por sobrecarga térmica ou descargas elétricas. Geralmente, os diodos danificados permanecem em curto-circuito, essa situação implica na desconexão de um grupo de células fotovoltaicas, o que reduz a tensão de circuito aberto. A degradação induzida por potencial (PID) também pode ser uma das causas.

Redução de I_{sc} pode ser causada pela LID, LeTID e por qualquer perda de transmitância óptica. Sendo que essas perdas estão relacionadas com as dificuldades da irradiação solar em atingir as células fotovoltaicas, o que se dá pela sujidade uniforme, sombreamento, descoloração e por nível excessivamente baixo de irradiância (sol próximo do horizonte).

Presença de degraus a presença de degraus indica a incompatibilidade entre diferentes áreas do arranjo fotovoltaico, o que pode ser causada por diversos fatores, como a presença de módulos parcialmente sujos e/ou sombreados.

2.4 MODELAGEM DE ARRANJOS FOTOVOLTAICOS

Os modelos matemáticos possuem o objetivo de prever comportamentos que podem ser medidos ou observados. Por exemplo, a modelagem de instalações fotovoltaicas permite estimar a geração de energia para uma dada condição de irradiância e temperatura. Assim, a potência estimada por um modelo pode ser comparada com a potência medida em campo, o que permite avaliar se os geradores fotovoltaicos estão operando adequadamente. Na literatura, estão disponíveis uma série de trabalhos que propõem diferentes técnicas para a modelagem de instalações fotovoltaicas. Destaca-se o grupo *Sandia National Laboratories* que atua no desenvolvimento e na análise de modelos fotovoltaicos com o objetivo de organizar um conjunto de informações de forma precisa e transparente.

Atualmente, existem softwares que prometem facilitar a modelagem de instalações fotovoltaicas. Essas ferramentas foram desenvolvidas para estimar o desempenho da geração e podem ser utilizadas tanto no projeto de novos sistemas como no monitoramento dos existentes. O PVsyst é um destes softwares e foi utilizado pelos autores Sharma e Chandel (2013) para avaliar o desempenho de uma instalação fotovoltaica. Uma outra opção é o PV Planner que permite calcular o rendimento da instalação ao considerar as perdas por sombreamento, refletividade, desempenho fora da STC, incompatibilidade de módulos, sujidade, perdas no inversor e no transformador. A análise de um sistema fotovoltaico através do PV Planner foi realizada por Shukla, Sudhakar e Baredar (2016). Por fim, destaca-se o PV*SOL, um dos softwares mais utilizados pela indústria para o planejamento de instalações fotovoltaicas. O PV*SOL permite planejar e simular todos os tipos de sistemas fotovoltaicos, desde as instalações residências com poucos módulos até grandes parques solares. Um estudo para identificar a viabilidade de uma

instalação fotovoltaica, por meio de análises fornecidas pelo PV*SOL, foi desenvolvida por Ahmed et al. (2022).

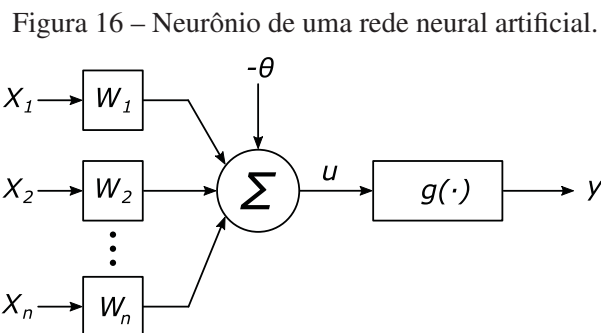
Os softwares atuam como uma interface para facilitar o processo de modelagem fotovoltaica por parte dos usuários. Internamente, estes softwares fazem o uso de modelos matemáticos, sendo que os mais empregados são os modelos baseados em inteligência artificial e os baseados em circuitos elétricos. A seguir, estes dois métodos de modelagem são detalhados.

2.4.1 Modelos baseados em inteligência artificial

Os arranjos fotovoltaicos são sistemas complexos e não-lineares. Devido à influência das condições climáticas na geração fotovoltaica é relativamente difícil modelar estes sistemas através de um modelo analítico ou numérico. No entanto, as técnicas de inteligência artificial (redes neurais, lógica Fuzzy, algoritmos genéticos, etc.) possibilitam resolver esse tipo de problema com certa facilidade (MELLIT; KALOGIROU, 2011).

As redes neurais artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso dos seres vivos, nos últimos anos, as RNAs se consolidaram em diversas áreas, como: reconhecimento de voz e de imagens; controle de qualidade na indústria; prevenção de falhas e controle de manutenção; previsão de produção; etc. No setor fotovoltaico, essa ferramenta está sendo empregada na execução de diferentes tarefas, tais como: detecção de falhas, previsão de geração, avaliação de desempenho, modelagem, rastreamento do ponto de máxima potência, etc.

Os neurônios artificiais utilizados nas RNAs realizam funções simples, como coletar sinais existentes em suas entradas, ponderá-los de acordo com a sua função operacional e produzir uma resposta considerando a função de ativação. Os neurônios em uma RNA podem ser implementados conforme mostra a Figura 16.



Fonte: Adaptado de Silva, Spatti e Flauzino (2010).

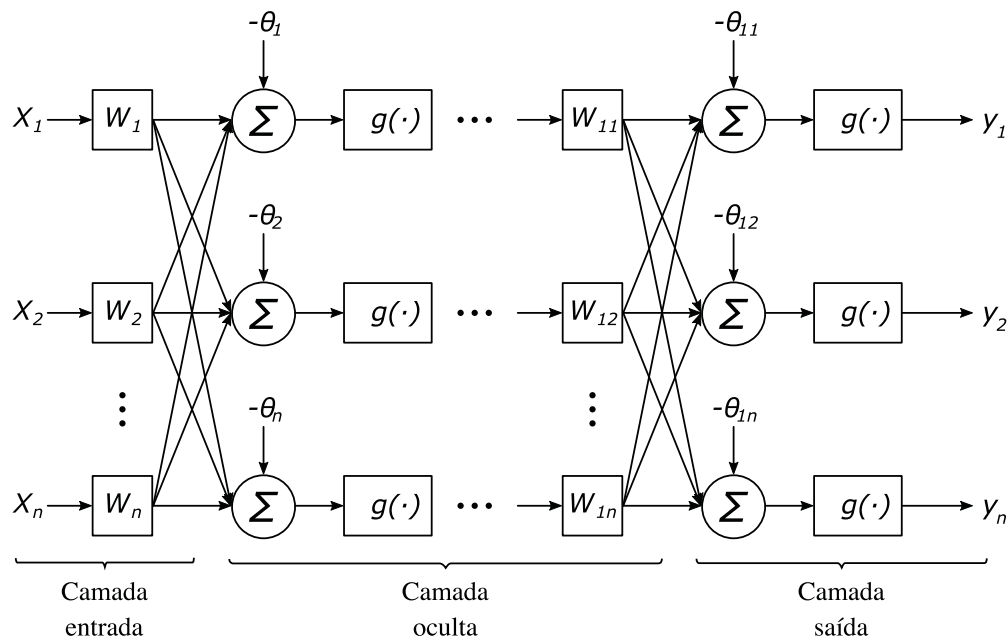
O sinais de entrada do neurônio artificial são formados pelo conjunto (X_1, X_2, \dots, X_n) , sendo este conjunto análogo aos impulsos captados pelos dendritos no neurônio biológico. As ponderações exercidas pelas junções sinápticas são representadas no neurônio artificial pelo conjunto de pesos (W_1, W_2, \dots, W_n) . O limiar (θ) , considerado por alguns autores como parte do conjunto de pesos, serve para aumentar o grau de liberdade no ajuste dos pesos. A saída do neurônio, denotada por u , é a soma ponderada de suas entradas. A função de ativação $g(\cdot)$ possui

o objetivo de limitar a saída do neurônio dentro de um intervalo de valores. Por fim, y consiste no valor final produzido pelo neurônio em relação a um determinado conjunto de entradas (SILVA; SPATTI; FLAUZINO, 2010).

A arquitetura de uma RNA define a forma como os seus diversos neurônios estão arranjados, um em relação ao outro. Basicamente, uma RNA pode ser dividida em três partes denominadas: camada de entrada, camada oculta e camada de saída. A camada de entrada é responsável pelo recebimento das informações provenientes do meio externo. A camada oculta realiza quase todo o processamento interno da rede. Por fim, a camada de saída é responsável pela apresentação dos resultados da rede (SILVA; SPATTI; FLAUZINO, 2010).

As principais arquiteturas das RNAs são: *feedforward* de camada simples, *feedforward* de múltiplas camadas, redes recorrentes e redes em estrutura reticulada. Sendo a arquitetura *feedforward* utilizada na maioria das aplicações. A RNA *perceptron* multicamadas, que faz parte das redes *feedforward*, é a mais utilizada na modelagem de arranjos fotovoltaicos. Essa arquitetura é caracterizada pela presença de pelo menos uma camada oculta de neurônios, situada entre a camada de entrada e a camada de saída, conforme mostra a Figura 17.

Figura 17 – Exemplo de uma rede neural artificial do tipo *perceptron* multicamadas.



Fonte: Adaptado de Silva, Spatti e Flauzino (2010).

O treinamento das RNAs consiste na aplicação de um algoritmo com o objetivo de ajustar os pesos e os limiares de seus neurônios para que as suas respostas estejam próximas dos valores desejados. As RNAs com arquitetura *feedforward* utilizam o treinamento supervisionado, sendo essa uma estratégia que consiste em utilizar um conjunto de amostras de treinamento, o qual é constituído pelos sinais de entradas e suas correspondentes saídas (SILVA; SPATTI; FLAUZINO, 2010).

O algoritmo mais aplicado no treinamento de RNAs com arquitetura *feedforward* de múltiplas camadas é denominado de *backpropagation*. Entretanto, diversas variações têm sido propostas a este algoritmo com o objetivo de tornar o processo de convergência mais eficiente. Uma análise de 14 algoritmos de treinamento foi realizada por Mekki, Mellit e Salhi (2016), sendo que o algoritmo *resilient-propagation*, também conhecido por *Rprop*, apresentou os melhores resultados. Um outro algoritmo frequentemente utilizado no treinamento de RNAs com aplicações fotovoltaicas é o *Levenberg-Marquardt*.

Por fim, destaca-se que em uma RNA, a quantidade de camadas ocultas e de neurônios que formam essas camadas são definidas através de regras heurísticas, ou seja, a rede é testada para diferentes topologias até encontrar aquela que apresenta a melhor performance. No entanto, devido a essa falta de sistematização, Lopez-Guede et al. (2016) desenvolveram um passo-a-passo que permite auxiliar no projeto de topologias de RNAs.

2.4.1.1 *Uso da inteligência artificial na modelagem fotovoltaica*

Uma RNA *perceptron* com três camadas foi proposta por Baptista et al. (2017) com o objetivo de estimar a potência gerada por um arranjo fotovoltaico. A rede foi treinada com o algoritmo *Levenberg-Marquardt* e destaca-se por utilizar apenas a irradiância solar como parâmetro de entrada. A topologia projetada foi a 1-3-1, ou seja, um neurônio na camada de entrada, três na camada oculta e um na camada de saída. A RNA foi implementada em hardware com um erro quadrático médio de 0,007%.

A RNA projetada por Almadhor (2018) é semelhante a anterior, ou seja, arquitetura *perceptron* com três camadas e treinada com o algoritmo *Levenberg-Marquardt*. No entanto, nessa proposta, a RNA é responsável por estimar a tensão e a corrente gerada pelo arranjo fotovoltaico. Os parâmetros de entrada da rede são: a irradiância solar, a temperatura ambiente, a temperatura do módulo, a umidade e a velocidade do vento. A RNA possui topologia 5-9-2 e alcançou a precisão de 93,9%.

Uma metodologia para identificar as situações de baixo desempenho em instalações fotovoltaicas foi proposta por Jiang e Maskell (2015). Nesse caso, uma RNA com topologia 2-15-15-1 foi treinada com o algoritmo *Levenberg-Marquardt* e utiliza a irradiância e a temperatura como entradas para estimar a potência do arranjo fotovoltaico. A potência estimada é comparada com a potência medida para detectar os períodos de baixo desempenho. O método permite a identificação dos fatores de degradação através da comparação entre a tensão de circuito aberto estimada com a tensão de circuito aberto medida.

Uma solução para o monitoramento a nível de módulo foi proposta por Samara e Natsheh (2019). Neste caso, cada módulo fotovoltaico é equipado com um microcontrolador, onde uma RNA está programada para avaliar o desempenho da geração. A rede neural foi treinada com o algoritmo *Levenberg-Marquardt* e possui a topologia 3-5-1. A camada de entrada é composta pela irradiação solar, temperatura e tensão de circuito aberto, enquanto a potência é estimada na camada de saída. Quando a potência estimada divergir em mais de 10% com relação a potência

medida, um alarme é emitido para a equipe de O&M.

Um método para localizar a posição exata de falhas em matrizes fotovoltaicas foi proposto por Karatepe, Hiyama et al. (2011). O método utiliza uma RNA com topologia 4-10-6, sendo a camada de entrada composta pela temperatura, irradiância, corrente e tensão do arranjo fotovoltaico. A camada de saída indica a tensão de cada um dos módulos que compõem o arranjo fotovoltaico, ou seja, nesse caso, o arranjo era composto por seis módulos. Para o treinamento da RNA foi utilizado o algoritmo *backpropagation*.

A RNA proposta por Leva et al. (2017) possui o objetivo de prever a geração fotovoltaica futura. Neste caso, as entradas da RNA são compostas pela previsão meteorológica, pelas coordenadas geográficas da matriz e pela data e hora. A saída da RNA estima a quantidade de energia que será produzido nas horas de luz solar do dia seguinte. O método proposto apresentou maior precisão nos dias ensolarados, sendo que a previsão meteorológica e os dados históricos para pré-processamento mostraram-se os principais gargalos para obter resultados melhores. A RNA foi treinada com o algoritmo *backpropagation*.

Usualmente, as RNAs são o método de inteligência artificial mais empregado na modelagem de arranjos fotovoltaicos. No entanto, existem outras técnicas como a lógica Fuzzy e os sistemas de inferência neuro-difuso adaptativos que também possibilitam a modelagem de instalações fotovoltaicas com bons resultados.

A lógica Fuzzy é uma metodologia que imita a capacidade humana de raciocínio impreciso e julgamento incerto. Se trata de uma metodologia apropriada para a modelagem a partir do conhecimento fornecido por um especialista, ou seja, o desempenho do sistema depende da experiência do especialista. Um sistema de lógica Fuzzy envolve três módulos: um difusor, um mecanismo de inferência e um defuzzificador. O difusor é usado para mapear o vetor de entradas em conjuntos difusos. O mecanismo de inferência processa os conjuntos difusos usando uma biblioteca de regras que são intuitivas e facilmente compreendidas pelos humanos. Por fim, o defuzzificador é usado para mapear os conjuntos difusos para vetores de saída, ou seja, produzir um valor real nítido para uma saída difusa (MELLIT; KALOGIROU, 2011).

Um método para modelagem de instalações fotovoltaicas utilizando a lógica Fuzzy foi proposto por Ducange et al. (2011). O método realiza a estimação da potência e através da comparação com a potência medida permite identificar as situações de baixo desempenho e emitir um alarme se diferença entre a potência estimada e a potência medida ultrapassar um valor limiar. O método é capaz de reconhecer mais de 90% das condições de falhas, mesmo na presença de dados ruidosos. Os autores identificaram que as situações do tipo falsos positivos foram ocasionadas por amostras medidas no início da manhã ou no final do período da tarde. Vale ressaltar que durante esses períodos a irradiância era muito baixa e a energia gerada é considerada desprezível.

A modelagem utilizando um Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) permite integrar a lógica difusa com as redes neurais artificiais. Portanto, trata-se de um modelo híbrido que permite utilizar as vantagens de cada uma das técnicas, minimizando suas limitações

e deficiências. Os modelos ANFIS unem a capacidade de aprendizagem e de tolerância a falhas das RNAs com a capacidade de interpretação dos sistemas de inferência Fuzzy.

A modelagem de um sistema fotovoltaico utilizando um sistema ANFIS foi proposto por Mellit e Kalogirou (2011). O modelo foi dividido em três partes, sendo elas: a matriz fotovoltaica, o banco de baterias e o controlador de carga. A comparação entre os dados medidos e estimados para cada modelo apresentou uma boa correspondência. O coeficiente de correlação foi de 98% para a energia consumida e 97% para a energia fornecida pelo sistema.

Em geral, o processo de modelagem fotovoltaica que emprega técnicas de inteligência artificial demanda de menor esforço. Contudo, os modelos que apresentam boa precisão exigem um grande conjunto de dados para a etapa de treinamento. Além disso, os modelos inteligentes não possuem a correspondência física com um circuito elétrico equivalente.

2.4.2 Modelos baseados em circuitos elétricos

Os circuitos elétricos podem ser utilizados na modelagem de instalações fotovoltaicas, sendo que, entre as principais topologias, estão: os modelos de diodo único com três, quatro e cinco parâmetros, além do modelo de diodo duplo com sete parâmetros. Os modelos são denominados dessa forma devido a quantidade de parâmetros que representam as propriedades dos módulos fotovoltaicos.

A estimação dos parâmetros desconhecidos dos modelos fotovoltaicos não é uma tarefa trivial, pois eles não são fornecidos diretamente pelos fabricantes e nem podem ser facilmente mensurados. Além disso, os parâmetros têm suas grandezas modificadas de acordo com as condições climáticas. No entanto, a literatura dispõe de técnicas para estimar o valor desses parâmetros, onde se destacam os seguintes métodos: analíticos, iterativos, otimização por metaheurísticas e inteligência artificial.

Normalmente, a escolha da topologia do circuito elétrico envolve a ponderação entre a precisão desejada, a complexidade para determinar os parâmetros desconhecidos e o custo computacional de implementação. Por exemplo, o modelo de diodo duplo com sete parâmetros mostrou-se, até o momento, um dos modelos com a maior precisão. Contudo, esse modelo possui alta complexidade e elevado custo computacional se comparado aos demais modelos.


A seguir, as principais topologias de circuitos utilizados na modelagem fotovoltaica são apresentadas. Posteriormente, os métodos para estimação dos parâmetros desconhecidos são elencados. Por fim, são expostas algumas aplicações dos modelos fotovoltaicos baseados em circuitos elétricos.

2.4.2.1 Os principais modelos baseados em circuito elétrico

Modelo de diodo único com três parâmetros o modelo consiste em um diodo conectado em antiparalelo com uma fonte de corrente, conforme mostra a Figura 18. A intensidade da corrente fotogerada (I_g) é diretamente proporcional à irradiância. Este modelo representa a

operação ideal de um módulo fotovoltaico. Logo, a topologia não é adequada para modelar um dispositivo real, pois as perdas do módulo são desprezadas (MITTAL et al., 2018).

Figura 18 – Modelo de diodo único com três parâmetros.



Fonte: Adaptado de Mittal et al. (2018).

Os três parâmetros desconhecidos deste modelo são: a corrente fotogerada (I_g), a corrente de saturação (I_{sat}) e o fator de idealidade (A). A equação que relaciona a corrente com a tensão de saída do módulo fotovoltaico é dada por:

$$I = I_g - I_{sat} \left[\exp\left(\frac{V}{A \cdot V_T} - 1\right) \right] \quad (13)$$


onde V_T representa a tensão térmica e pode ser calculada por:

$$V_T = \frac{N_s \cdot k \cdot T}{q} \quad (14)$$

onde q é a carga elétrica de um elétron, k é a constante de Boltzmann, N_s é a quantidade de células fotovoltaicas conectadas em série no módulo e T é a temperatura de operação do módulo.

Modelo de diodo único com quatro parâmetros trata-se de uma topologia que já permite modelar um módulo fotovoltaico real. Neste caso, algumas perdas começam a ser modeladas através da inclusão de uma resistência em série (R_s), conforme mostra a Figura 19.

Figura 19 – Modelo de diodo único com quatro parâmetros.



Fonte: Adaptado de Mittal et al. (2018).


A inclusão de R_s possibilita modelar a soma das resistências internas de um módulo, como a resistência do contato entre a superfície do silício e os eletrodos (KHAN et al., 2019). A equação que relaciona a corrente e a tensão de saída é definida por:

$$I = I_g - I_{sat} \left[\exp \left(\frac{V + I \cdot R_s}{A \cdot V_T} - 1 \right) \right] \quad (15)$$

Os quatro parâmetros desconhecidos deste modelo são: I_g , I_{sat} , A e R_s . Destaca-se que esse modelo ainda não considera a corrente de fuga da junção p-n das células fotovoltaicas. Isso resulta em imprecisão, principalmente quando o módulo é submetido a variações nas condições climáticas (MITTAL et al., 2018).

Modelo de diodo único com cinco parâmetros é um modelo de alta precisão se comparado aos anteriores. Esse modelo possui o acréscimo de uma resistência em paralelo (R_p), conforme mostra a Figura 20.

Figura 20 – Modelo de diodo único com cinco parâmetros.



Fonte: Adaptado de Mittal et al. (2018).

Os parâmetros desconhecidos deste modelo são: I_g , I_{sat} , A , R_s e R_p . A equação que relaciona a corrente e a tensão de saída é dada por:

$$I = I_g - I_{sat} \left[\exp \left(\frac{V + I \cdot R_s}{A \cdot V_T} - 1 \right) \right] - \frac{V + I \cdot R_s}{R_p} \quad (16)$$


O modelo com cinco parâmetros é um dos mais utilizados devido ao seu custo-benefício, ou seja, a relação entre a precisão e a complexidade de implementação. No entanto, esse modelo apresenta deficiências em situações de baixa irradiação solar (JORDEHI, 2016).

Modelo de diodo duplo com sete parâmetros possui alta concordância com a resposta de um módulo fotovoltaico real. Entre os modelos apresentados, trata-se do mais preciso, contudo, também é o mais complexo. O modelo com sete parâmetros possui o acréscimo de um segundo diodo, conforme mostra a Figura 21.

A adição do segundo diodo permite modelar as perdas devido à corrente de recombinação na região de depleção das células fotovoltaicas (JORDEHI, 2016). Os parâmetros desconhecidos deste modelo são: I_g , I_{sat1} , I_{sat2} , A_1 , A_2 , R_s e R_p . A equação que relaciona a corrente e a tensão de saída é dada por:

$$I = I_g - I_{sat1} \left[\exp \left(\frac{V + I \cdot R_s}{A_1 \cdot V_{T1}} - 1 \right) \right] - I_{sat2} \left[\exp \left(\frac{V + I \cdot R_s}{A_2 \cdot V_{T2}} - 1 \right) \right] - \frac{V + I \cdot R_s}{R_p} \quad (17)$$

Figura 21 – Modelo de diodo duplo com sete parâmetros.



Fonte: Adaptado de Mittal et al. (2018).

2.4.2.2 Outros circuitos elétricos empregados na modelagem fotovoltaica

Os circuitos elétricos apresentados anteriormente são considerados como circuitos clássicos da modelagem fotovoltaica. Contudo, existem outras propostas que merecem destaque. No entanto, vale ressaltar que a aplicabilidade desses outros modelos não é tão comum, pois a complexidade de implementação normalmente é superior, se comparada aos circuitos clássicos.

Modelo de diodo duplo dependente do clima os modelos clássicos permitem estimar a resposta de um módulo fotovoltaico para uma condição climática específica (irradiância e temperatura fixas). Bradaschia et al. (2019) utilizaram o modelo clássico de diodo duplo para propor uma análise dependente da irradiância e da temperatura. Nesse caso, os parâmetros do modelo são definidos em função da condição climática, o que possibilita o uso do modelo sob níveis distintos de irradiância e temperatura.

Modelo de diodo único com capacitor ao conectar o módulo fotovoltaico a uma carga, a tensão permanece quase no mesmo valor por alguns microssegundos. Isso pode ser explicado pela capacitância da junção p-n. O comportamento dessa capacitância foi modelado por Suskis e Galkin (2013). A principal vantagem desse circuito está na modelagem do regime transitório dos módulos.

Modelo de diodo duplo simplificado o modelo possui uma fonte de corrente e dois diodos, excluindo as resistências série e paralela que estão presentes no modelo de diodo duplo com sete parâmetros. O objetivo desta modificação está em reduzir o tempo computacional de implementação. O modelo, proposto por Babu e Gurjar (2014), possui apenas quatro parâmetros desconhecidos e o cálculo desses parâmetros é realizado de maneira analítica, sem a necessidade de qualquer simplificação.

Modelo de diodo triplo com nove parâmetros conforme o nível de precisão desejado, o modelo de diodo duplo com sete parâmetros pode ser insuficiente em algumas aplicações. Neste caso, uma opção é o modelo de diodo triplo com nove parâmetros, o qual é considerado um dos modelos de maior precisão já desenvolvido. Porém, trata-se de um circuito de alta complexidade na determinação dos parâmetros (IBRAHIM et al., 2020).

Uma modificação no modelo de diodo triplo foi proposta por Nishioka et al. (2007). Os autores adicionaram resistências em série com cada um dos diodos, a modificação

possibilitou a modelagem de células policristalinas com dimensões reduzidas (3x3 mm). O objetivo das resistências em série está na representação das correntes de fuga que são mais proeminentes nesse tipo de célula fotovoltaica.

Uma outra modificação no modelo de diodo triplo foi proposta por Mazhari (2006). Nesse caso, a justificativa está na necessidade de modelar células fotovoltaicas orgânicas. Os modelos clássicos são inadequados para modelar esse tipo de células, pois assumem que a corrente fotogerada é constante para determinada intensidade de irradiação e independente da tensão. Essa suposição é razoável para células inorgânicas, mas não se aplica às orgânicas.

Modelo de diodo multidimensional Soon, Low e Goh (2014) propuseram um método que permite ao usuário escolher a quantidade de diodos que compõem o modelo. Apesar dos modelos de diodo único e de diodo duplo serem adequados para a modelagem de módulos fotovoltaicos mono e policristalinos, isso não se aplica aos módulos de filmes finos. Os diodos adicionais introduzem uma maior quantidade de parâmetros, o que permite aumentar o grau de liberdade para o ajuste da curva I-V de módulos com diferentes tecnologias.

2.4.2.3 Métodos para estimação dos parâmetros

Os fabricantes de módulos fotovoltaicos, em geral, fornecem em seus catálogos os seguintes parâmetros: corrente de curto-circuito (I_{sc}), tensão de circuito aberto (V_{oc}), potência máxima (P_{mp}), corrente no ponto de máxima potência (I_{mp}), tensão no ponto de máxima potência (V_{mp}) e os coeficientes de temperatura ($\alpha_{I_{sc}}$, $\beta_{V_{oc}}$ e $\gamma_{P_{mp}}$). Os parâmetros que representam as propriedades dos módulos e são necessários para os modelos vistos anteriormente, como: I_g , I_o , R_s , R_p e a não são fornecidos nos catálogos e nem podem ser facilmente mensurados. Portanto, um método matemático deve ser aplicado para estimar esses parâmetros.

O principal desafio ao utilizar os modelos elétricos está na estimação de seus parâmetros. Na literatura são relatados inúmeros métodos que prometem resolver esse problema, mas até o momento nenhum foi adotado como padrão pela comunidade. Vale destacar que, o método deve ser escolhido com cautela, pois as incertezas em relação aos parâmetros estimados podem contribuir para a incerteza atribuída às previsões de desempenho realizadas pelo modelo (HANSEN; STEIN; LUKETA-HANLIN, 2013).

Em geral, os parâmetros são estimados através de uma função objetivo para minimizar o erro médio entre a corrente estimada pelo modelo e a corrente medida. Os métodos podem ser classificados em dois grupos: os determinísticos e os heurísticos. Entre os métodos determinísticos estão os analíticos e os iterativos, já entre os métodos heurísticos estão os de otimização por metaheurísticas e os baseados em inteligência artificial. A seguir, os métodos supracitados são detalhados:

Métodos analíticos trata-se da forma mais simples de estimar os parâmetros dos modelos fotovoltaicos, mas é um procedimento que exige uma série de simplificações devido à não-linearidade dos modelos. Por exemplo, muitos autores assumem que o fator de idealidade (a) possui um valor constante. Em resumo, apesar da facilidade de implementação, os métodos analíticos possuem baixa precisão devido as simplificações (JORDEHI, 2016).

A literatura científica dispõe de um conjunto de trabalhos que propõem distintas abordagens analíticas para a estimação dos parâmetros, como os trabalhos propostos por Brano et al. (2010), Bai et al. (2014) e Mares, Paulescu e Badescu (2015). Apesar desses trabalhos empregarem métodos analíticos na estimação dos parâmetros, eles divergem entre si em relação a complexidade de implementação e a precisão.

Métodos iterativos os modelos possuem equações não-lineares que podem ser resolvidas utilizando métodos computacionais iterativos, como Newton-Raphson ou o método da bissecção. Esses métodos, geralmente, não estão sujeitos a muitas simplificações como ocorre com os métodos analíticos. Entretanto, as soluções normalmente dependem da inicialização de alguns parâmetros, o que pode resultar em ótimos locais ao invés de ótimos globais (IBRAHIM et al., 2020).

O trabalho desenvolvido por Sera, Teodorescu e Rodriguez (2007) destaca-se pela proposta de uma metodologia que permite estimar os parâmetros do modelo de diodo único com cinco parâmetros utilizando apenas os dados de catálogo do módulo fotovoltaico. Essa metodologia possibilita o uso do método de Newton-Raphson ou o método da bissecção e apresenta boa concordância com as especificações de catálogo do módulo.

Uma comparação entre três algoritmos que utilizam abordagens determinísticas foi realizada por Ayodele, Ogunjuyigbe e Ekoh (2016). Os algoritmos são utilizados para determinar os parâmetros do modelo de diodo único de cinco parâmetros. Os autores investigaram a precisão, a robustez, o tempo computacional e a facilidade de implementação.

Otimização por metaheurísticas são alternativas eficientes para o cálculo dos parâmetros, pois possuem a capacidade de solucionar funções não-lineares através da minimização ou maximização de uma função objetivo. Destacam-se os métodos de enxame de partículas, colônia artificial de abelhas, algoritmos genéticos e evolução diferencial (ISHAQUE; SALAM, 2011).

Os algoritmos de otimização não estão sujeitos à premissas simplificadoras e são poderosos em termos de capacidade de otimização global. No entanto, a velocidade de convergência é baixa e, geralmente, esses algoritmos requerem milhares de iterações para obterem resultados satisfatórios. O desempenho dos métodos de otimização por metaheurísticas depende em grande parte do ajuste adequado dos parâmetros de controle, pois qualquer escolha inadequada pode levar a uma convergência lenta ou ao término precoce da otimização (CHEN et al., 2020).

O uso do algoritmo de evolução diferencial na estimação dos cinco parâmetros do modelo de diodo único foi realizado por Ishaque e Salam (2011). Já os autores Ibrahim et al. (2020) utilizaram um método de otimização para determinar os parâmetros desconhecidos do modelo de diodo triplo. Uma revisão bibliográfica com os principais algoritmos de otimização por metaheurísticas aplicados na modelagem fotovoltaica foi realizada por Jordehi (2016).

Inteligência artificial as técnicas de inteligência artificial não estão restritas ao processo de modelagem fotovoltaica, o uso destes métodos no processo de estimação dos parâmetros de modelos fotovoltaicos merece destaque. Em especial, o uso das redes neurais artificiais.

O uso de uma RNA para estimar os parâmetros do modelo de diodo único com cinco parâmetros foi realizado por Gastli, Ben-Brahim e Rhouma (2015). A RNA foi projetada com topologia 7-15-3, sendo que os parâmetros determinados pela rede são: a resistência série, a corrente de saturação reversa e o fator de idealidade. Na camada de entrada são inseridos os parâmetros de catálogo do módulo, alguns pontos da curva I-V e o valor da resistência paralela. Os dados utilizados no treinamento da RNA foram gerados através de simulações no software Matlab.

Um Sistema de Inferência Neuro-Fuzzy Adaptativo foi utilizado por Kulaksız (2011) para estimar os parâmetros do modelo de diodo único com cinco parâmetros. O sistema permite determinar os parâmetros para módulos com diferentes tecnologias, como os monocristalinos, policristalinos e de filmes finos. A entrada do sistema ANFIS é composta pelo tipo da tecnologia, a tensão de circuito aberto, a corrente de curto-circuito e um parâmetro obtido a partir da curva I-V. Os parâmetros de saída são: a resistência série, a resistência paralela e o fator de idealidade.

Ao final dessa análise, pode-se concluir que não existe um método que seja ótimo para todos os casos. Portanto, destaca-se que, independentemente do método escolhido, o algoritmo deve apresentar as seguintes características: boa precisão; capacidade de adaptação, ou seja, convergir adequadamente ao utilizar conjuntos de dados distintos para treinamento; robustez, ou seja, apresentar resultados semelhantes quando submetido ao mesmo conjunto de dados; baixo tempo computacional.

2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Esse capítulo abordou o referencial teórico e tinha como objetivo embasar o leitor em relação ao monitoramento e a avaliação de desempenho de usinas fotovoltaicas. Foram apresentados os fatores que influenciam a geração, os detalhes técnicos relacionados com a medição dos parâmetros elétricos e climáticos, a importância das curva I-V no monitoramento e os principais métodos de modelagem fotovoltaica.

A geração fotovoltaica é influenciada pela irradiância e pela temperatura de operação das células. Contudo, existem muitos outros fatores que podem ocasionar perdas na geração. Destacam-se: a incompatibilidade de módulos, a LID, a sujidade, o sombreamento, a PID, etc. O conhecimento desses fatores é essencial para compreender a importância do monitoramento fotovoltaico.

A aquisição de curvas I-V envolve a medição de parâmetros elétricos e climáticos. Destaca-se que, as medições em instalações fotovoltaicas exigem cuidados que vão além do nível de precisão dos sensores, mas a localização, a instalação e o processo de manutenção são essenciais para garantir a correspondência entre os dados adquiridos com os valores reais. Os processos de medição são regulados por uma série de normas e o projeto do traçador de curvas I-V proposto no próximo capítulo foi realizado conforme as especificações da IEC 61724-1 e das demais legislações vigentes.

A análise das curvas I-V mostra-se uma excelente ferramenta para a avaliação de desempenho de instalações fotovoltaicas. Através das curvas é possível identificar os parâmetros de interesse, calcular quantitativamente as perdas da geração e obter informações valiosas sobre os fatores de degradação. A aquisição das curvas pode ser realizada através de diferentes métodos, onde destaca-se o método da carga capacitiva.

A grande maioria dos trabalhos que foram propostos pela comunidade científica e as principais soluções comerciais que realizam o diagnóstico da geração fotovoltaica utilizam os modelos matemáticos para estimar a potência das instalações fotovoltaicas. A comparação entre a potência medida em campo com a potência estimada por um modelo permite identificar os períodos de baixo desempenho. Entre os modelos fotovoltaicos se destacam aqueles que fazem uso de técnicas de inteligência artificial e, principalmente, os modelos baseados em circuitos elétricos.

Até o momento não existe um consenso na comunidade científica em relação aos métodos que podem ser aplicadas na identificação e classificação dos fatores de degradação. A literatura dispõe de uma infinidade de abordagens que variam quanto a complexidade de implementação e a precisão obtida. No entanto, a maioria das metodologias convergem quanto a importância do uso de técnicas de inteligência artificial. Algumas pesquisas que investigam o diagnóstico da geração fotovoltaica estão destacadas na Seção 1.1.1 deste trabalho.

Por fim, deve-se salientar que a maioria das pesquisas que investigam o monitoramento e o diagnóstico da geração utilizam dados simulados ou dados reais obtidos em arranjos fotovoltaicas de pequeno porte. Esses dados podem divergir dos resultados que são alcançados em instalações fotovoltaicas reais e que possuem maior potência nominal. Portanto, as propostas deste trabalho que envolvem o projeto de um traçador de curvas I-V integrado à usinas e de uma metodologia para diagnóstico da geração fotovoltaica são desenvolvidas e validadas em uma usina fotovoltaica real.

3 TRAÇADOR DE CURVAS I-V INTEGRADO À USINA

A medição da curva I-V tem se mostrado uma ótima ferramenta para avaliar o desempenho de usinas fotovoltaicas. A análise da curva permite aferir alguns pontos de interesse (P_{mp} , I_{sc} , V_{oc} , I_{mp} e V_{mp}), identificar as situações de baixo desempenho, calcular quantitativamente as perdas da geração e diagnosticar os principais fatores de degradação.

O mercado fotovoltaico dispõe de soluções comerciais para a medição de curvas I-V. Contudo, as soluções automatizadas ainda são praticamente inexistentes e as manuais implicam na exposição dos operadores à circuitos elétricos de alta potência e, conseqüentemente no risco de choque elétrico. Além disso, a medição manual das curvas I-V de todas as séries fotovoltaicas que compõem uma usina pode demorar dias, ou até mesmo, semanas.

O uso de traçadores de curvas I-V no monitoramento contínuo de usinas exige a aquisição diária de uma ou mais curvas I-V de cada série fotovoltaica. Afinal, os módulos fotovoltaicos podem permanecer com falhas no período entre as aquisições e a equipe de O&M não vai identificá-las, o que resulta em perdas significativas na geração. Assim sendo, o monitoramento contínuo de usinas exige uma taxa de aquisição de curvas que pode inviabilizar o uso dos traçadores manuais.

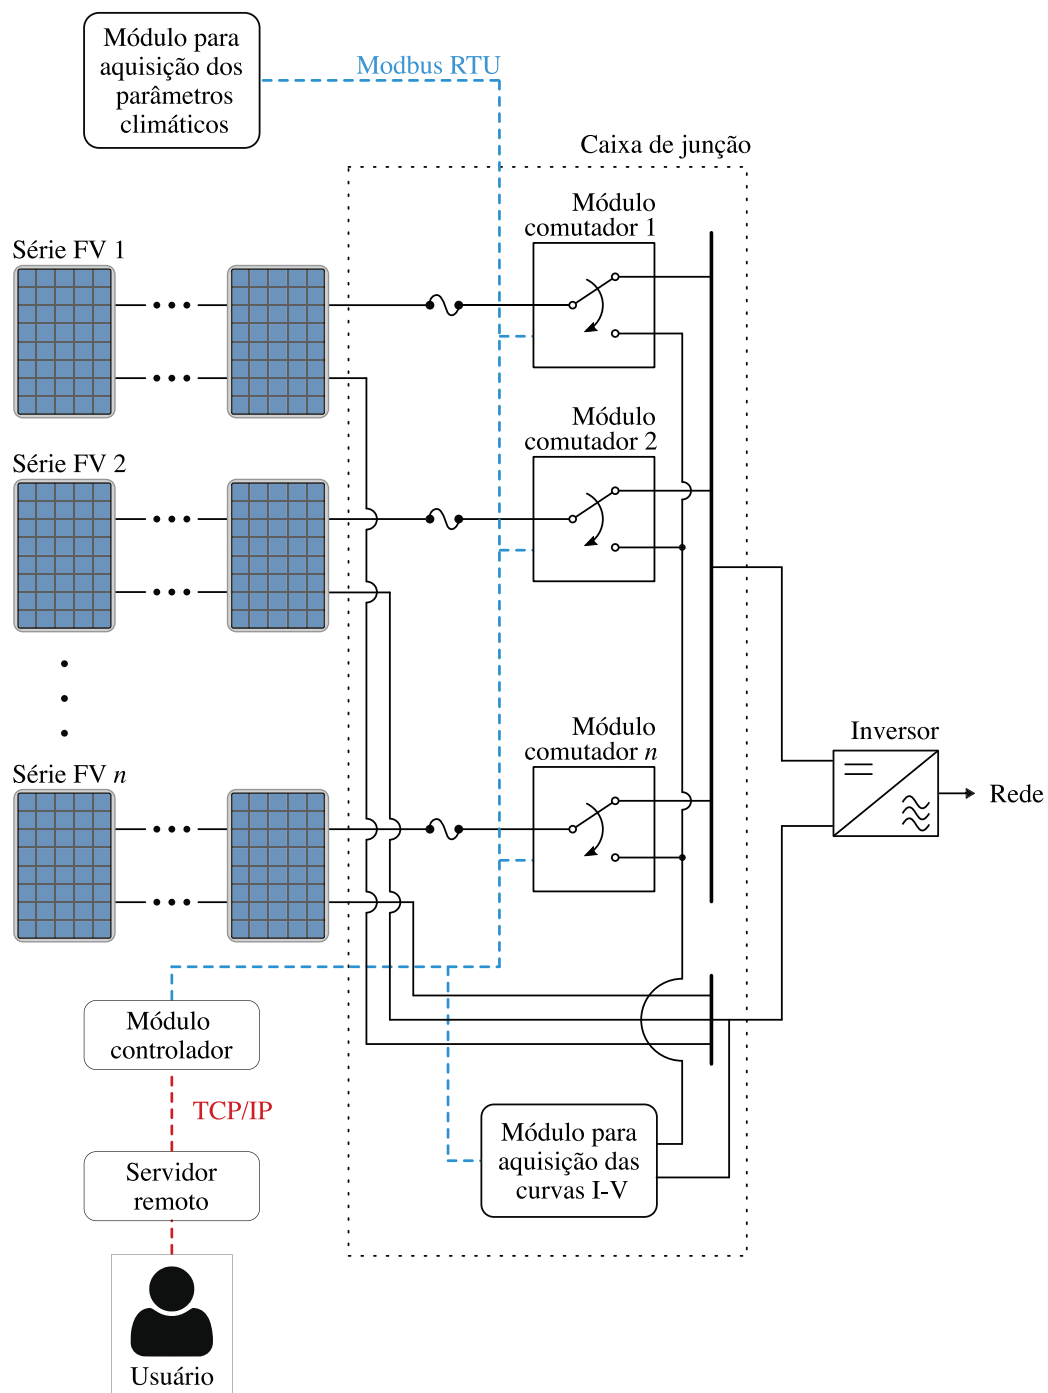
Com o objetivo de resolver os problemas supracitados, este trabalho propõe o projeto de um traçador de curvas I-V automático para ser integrado à usinas fotovoltaicas, conforme a topologia mostrada na Figura 22. O projeto do traçador de curvas proposto é dividido em módulos, sendo eles: os comutadores, o módulo para aquisição das curvas I-V, o módulo para aquisição dos parâmetros climáticos e o módulo controlador.

Na topologia proposta, cada uma das séries fotovoltaicas que compõem a matriz é equipada com um módulo comutador, sendo este módulo responsável pelas tarefas de conexão e desconexão da série com o inversor fotovoltaico e com o módulo para aquisição das curvas I-V. Por exemplo, para medir uma curva I-V, o comutador desconecta a série FV do inversor e a conecta ao módulo para aquisição das curvas I-V. Após a medição, o comutador realiza o processo inverso para reconectar a série ao inversor.

O módulo para aquisição das curvas I-V é responsável por mensurar os valores de corrente e tensão da curva I-V, sendo composto pelos circuitos de sensoriamento, operacional, processamento e pela carga capacitiva. Destaca-se que um conjunto de séries fotovoltaicas pode ser conectado no mesmo módulo para aquisição das curvas I-V, não sendo necessário o emprego de módulos individuais para cada série FV, o que reduz a quantidade de hardware e, conseqüentemente, os custos do projeto.

O registro das curvas I-V deve vir acompanhado de informações referentes às condições climáticas do instante do ensaio. Assim sendo, o módulo proposto para aquisição dos parâmetros climáticos é responsável por medir a irradiância no plano inclinado e a temperatura de operação dos módulos.

Figura 22 – Topologia do traçador de curvas I-V proposto.



Fonte: Elaborada pelo autor (2020).

O controle das tarefas que envolvem o processo de aquisição das curvas I-V é executado pelo módulo controlador, sendo este responsável por comandar os comutadores, o módulo para aquisição das curvas I-V e o módulo para aquisição dos parâmetros climáticos. Além disso, o controlador realiza o armazenamento interno dos dados mensurados e o espelhamento desses registros para um servidor remoto.

A comunicação entre os módulos que compõem o traçador de curvas I-V é realizada através de um barramento RS-485, via protocolo Modbus RTU. A rede opera com a lógica mestre-escravo, onde o mestre é o módulo controlador e os demais dispositivos que compõem o traçador de curvas são os escravos.

O traçador de curvas I-V foi projetado para ser instalado na caixa de junção ou no eletrocentro de usinas fotovoltaicas. Vale salientar que a principal delimitação do equipamento proposto está na rede de comunicação. O padrão RS-485 não determina a quantidade máxima de dispositivos que podem ser interligados na rede, mas sim uma série de parâmetros que são utilizados para o cálculo deste limite. A partir destes cálculos e considerando o uso dos resistores de terminação nos dois extremos do barramento determina-se o limite de 32 dispositivos com carga unitária. No entanto, a quantidade de dispositivos pode aumentar com o uso de repetidores de sinal (NOVUS, 2011). Portanto, em usinas fotovoltaicas de grande porte, o quantitativo mínimo de traçadores está diretamente relacionado com a quantidade de séries fotovoltaicas.

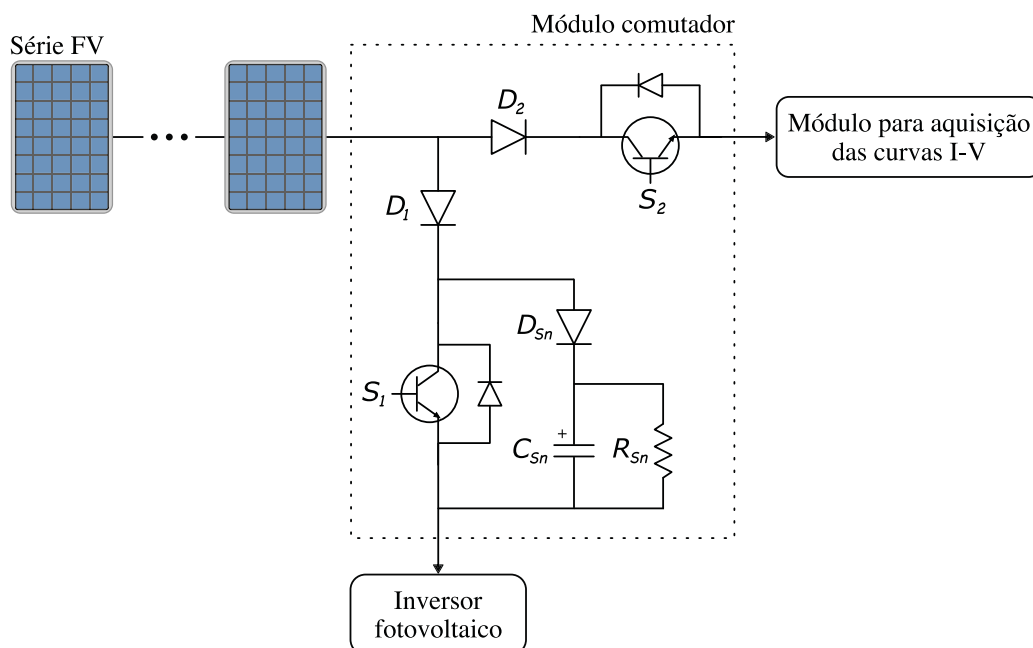
A seguir, a solução proposta para medição automática de curvas I-V é apresentada, o projeto dos módulos comutadores está contido na Seção 3.1, do módulo para aquisição das curvas I-V na Seção 3.2, do módulo para medição dos parâmetros climáticos na Seção 3.3 e do módulo controlador na Seção 3.4. O traçador de curvas I-V é projetado para ser instalado em uma usina fotovoltaica composta por séries com tensão de circuito aberto de 900 V e corrente de curto-circuito de 9 A. No entanto, vale mencionar que essa mesma metodologia de projeto pode ser aplicada em séries com níveis maiores de tensão e corrente.

3.1 MÓDULO COMUTADOR

Os módulos comutadores possuem a função de conexão e desconexão das séries fotovoltaicas com o inversor e com o módulo para aquisição das curvas I-V. Assim sendo, cada uma das série FV que compõem a matriz da usina é conectada a um módulo comutador. A topologia desse módulo possui dois braços, cada um composto por um diodo e um transistor em série, conforme mostra a Figura 23.

Ao iniciar o processo de aquisição de novas curvas I-V, o comutador da primeira série FV recebe um comando do módulo controlador para desconectar a série do inversor e conectá-la ao módulo para aquisição de curvas I-V. Assim sendo, o transistor S_1 para de conduzir e S_2 entra em condução. Em seguida, após a aquisição da curva, o comutador recebe outro comando, agora para reconectar a série ao inversor. Em seguida, o próximo comutador executa os mesmos procedimentos e assim sucessivamente até que todas as curvas I-V sejam mensuradas.

Figura 23 – Topologia do módulo comutador.



Fonte: Elaborada pelo autor (2020).

Cada módulo comutador é composto pelos circuitos de alimentação, processamento, comunicação, comando dos transistores e refrigeração. O projeto destes circuitos é detalhado a seguir:

Circuito de alimentação todos os módulos que compõem o traçador de curvas I-V seguem o padrão industrial e foram projetados para serem alimentados em corrente contínua com tensão de 24 V, sendo protegidos contra sobrecorrente, sobretensão e inversão de polaridade. Destaca-se que o uso de uma fonte de alimentação ininterrupta (UPS, do acrônimo em inglês *Uninterruptible Power Supply*) possibilita que o traçador de curvas I-V mantenha-se sempre em operação.


Circuito de processamento as tarefas de processamento são executadas por um microcontrolador ATmega328p, sendo este responsável pela comunicação, pelo comando dos transistores (S_1 e S_2) e pelo controle térmico. O ATmega328p faz parte da família de microcontroladores de 8 bits fabricados pela ATMEL e a sua escolha é justificada pela sua simplicidade, baixo consumo de energia, alta disponibilidade no mercado e significativa confiabilidade, pois trata-se do microcontrolador utilizado nas plataformas de prototipagem Arduino.

Circuito de comunicação o processo de adquirir automaticamente as curvas I-V de um conjunto de séries fotovoltaicas e a necessidade de mensurar os parâmetros climáticos a cada ensaio implica na necessidade dos módulos que compõem o traçador de curvas trocarem informações entre si. Essa comunicação ocorre através do protocolo de comunicação Modbus RTU. A escolha pelo Modbus é justificada por se tratar de um protocolo aberto,

desenvolvido na década de 70 e consolidado na indústria, além de ser o protocolo mais utilizados em aplicações fotovoltaicas. O padrão Modbus RTU pode operar com taxas de transmissão de até 12 Mbps e permite a distância máxima de 1.200 metros.

O circuito de comunicação foi projetado com base no conversor de sinal MAX485, sendo este responsável pela interface entre o barramento de comunicação RS-485 e o microcontrolador ATmega328p. O circuito possui proteções contra danos eletrostáticos e transientes elétricos através de um diodo TVS, modelo SM712. Além disso, indutores de modo comum estão presentes e atuam como filtros. A placa eletrônica do módulo para a comunicação é mostrado na Figura 24.

Figura 24 – Placa eletrônica do módulo para comunicação via RS-485.



Fonte: Elaborada pelo autor (2022).

Circuito de comando do transistor S_1 a conexão da série fotovoltaica com o inversor ocorre através do braço composto pelo transistor S_1 e o diodo D_1 . O transistor S_1 é bloqueado sob carga, ou seja, há condução de corrente elétrica no momento da desconexão com o inversor. Soma-se à essa condição, a característica indutiva destes circuitos devido aos cabos com longa extensão que as séries fotovoltaicas possuem. Portanto, a abertura destes circuitos causa picos de sobretensão. Sendo que, quanto maior for a distância entre a série fotovoltaica e o módulo comutador, maior será a indutância do circuito e, conseqüentemente, maior a sobretensão. De acordo com Grover (2004), a indutância do cabo pode ser estimada por:

$$L_{cabo} = 2L \left\{ \ln \left[\left(\frac{2L}{d} \right) \left(1 + \sqrt{1 + \left(\frac{d}{2L} \right)^2} \right) \right] - \sqrt{1 + \left(\frac{d}{2L} \right)^2} + \frac{\mu}{4} + \frac{d}{2L} \right\} \quad (18)$$


onde: L_{cabo} é a indutância do cabo, em nano henries (nH). L é o comprimento do cabo, em cm. d é o diâmetro do cabo, em cm. μ é a permeabilidade magnética relativa do material, parâmetro adimensional.

Para atenuar o pico de sobretensão no transistor foi projetado um circuito de grampeamento, também denominado de *snubber*. O circuito escolhido é do tipo RCD, ou seja, composto

por uma resistência (R_{Sn}), um capacitor (C_{Sn}) e um diodo (D_{Sn}), conforme mostra a Figura 23. O *snubber* opera da seguinte forma: quando o transistor parar de conduzir, a energia é armazenada pelo capacitor e quando o transistor entrar em condução, a energia armazenada é dissipada pelo resistor. Assim, quanto maior for a capacitância, menor será a sobretensão. Porém, maior será a potência dissipada por este circuito.

Um ensaio prático mostrou a influência da indutância do cabo na desconexão de uma série FV. Neste ensaio foi realizada a abertura de uma série de 6,48 kW, a série foi conectada ao inversor com um cabo de 6 mm² e com cerca de 80 m de comprimento. De acordo com a equação (18), a indutância deste cabo é de aproximadamente 175 μ H. Durante o ensaio, a tensão da série FV no ponto de máxima potência era de 700 V e a tensão de circuito aberto de 865 V. Ao realizar a abertura deste circuito, sem utilizar um circuito de grampeamento, ocorreu um pico de tensão que atingiu 1.345 V, conforme mostra a Figura 25.

Figura 25 – Influência da indutância do cabo na desconexão de séries fotovoltaicas.



Fonte: Elaborada pelo autor (2018).

A escolha dos semicondutores deve ocorrer com base nas características elétricas das séries fotovoltaicas. Portanto, nesse caso, optou-se por dispositivos com a capacidade de suportar níveis de tensão superiores à 30% da tensão de circuito aberto da série fotovoltaica (900 V). Assim, o circuito foi projetado com o transistor (S_1) do modelo IHW20N120R3, cujas principais especificações técnicas estão elencadas na Tabela 5. O comando do transistor (S_1) ocorre através do optoacoplador TLP250, o qual é um circuito integrado projetado para o comando de IGBTs e que possui a capacidade de isolamento de 2.500 V. Além disso, o circuito foi projetado com o diodo (D_1) do modelo DSEP30-12A, cujas especificações são mostradas na Tabela 6. Por fim, o circuito de *snubber* para eliminar a sobretensão foi projetado de forma heurística com o diodo RHRP8120, a capacitância de 13 nF e a resistência de 4,7 M Ω .

Tabela 5 – Principais especificações técnicas do transistor IHW20N120R3.

Parâmetro	Valor
Tensão máxima de bloqueio	1200 V
Corrente máxima de condução ($T_j = 100\text{ °C}$)	20 A
Queda de tensão reversa ($T_j = 125\text{ °C}$)	1,7 V

Fonte: Elaborada pelo autor (2022).

Tabela 6 – Principais especificações técnicas do diodo DSEP30-12A.

Parâmetro	Valor
Tensão máxima de bloqueio	1200 V
Corrente máxima de condução ($T_j = 120\text{ °C}$)	30 A
Queda de tensão reversa ($T_j = 25\text{ °C}$)	2,74 V

Fonte: Elaborada pelo autor (2022).

Circuito de comando do transistor S_2 a conexão da série fotovoltaica com o módulo para aquisição das curvas I-V ocorre através do braço composto pelo diodo D_2 e o transistor S_2 . Neste caso, o transistor entra em condução quando a série fotovoltaica estiver desconectada do inversor e a condução vai ser interrompida somente quando a carga capacitiva estiver completamente carregada. Logo, o transistor S_2 nunca é bloqueado sob carga e, assim sendo, não está sujeito a picos de sobretensão.

Assim como no caso anterior, o modelo do transistor empregado é o IHW20N120R3 com acionamento através do optoacoplador TLP250. No entanto, o modelo do diodo escolhido para este circuito é o 10A10, cujas principais especificações estão elencadas na Tabela 7. A escolha se deu pelo fato do diodo D_2 permanecer em condução durante poucos milissegundos e, conseqüentemente, dissipar pouca potência. O modelo 10A10 possui um invólucro menor e o custo reduzido.


Tabela 7 – Principais especificações técnicas do diodo 10A10.

Parâmetro	Valor
Tensão máxima de bloqueio	1000 V
Corrente máxima de condução ($T_j = 60\text{ °C}$)	10 A
Queda de tensão reversa ($T_j = 25\text{ °C}$)	1,1 V

Fonte: Elaborada pelo autor (2022).

Circuito para refrigeração o objetivo do cálculo térmico está na garantia de manter a temperatura de junção dos componentes semicondutores (diodos e transistores) abaixo do valor máximo definido pelos fabricantes. Para o cálculo térmico, de acordo com Barbi (2014), pode-se considerar o circuito da Figura 26.

Figura 26 – Circuito para o projeto térmico do dissipador.



Fonte: Barbi (2014).

No circuito para o projeto térmico do dissipador tem-se que: T_j é a temperatura na junção, em °C. T_C é a temperatura do encapsulamento, em °C. T_D é a temperatura do dissipador, em °C. T_a é a temperatura ambiente, em °C. R_{jC} é a resistência térmica entre a junção e o encapsulamento, em °C/W. R_{CD} é a resistência térmica entre o encapsulamento e o dissipador, em °C/W. R_{Da} é a resistência térmica entre o dissipador e o ambiente, em °C/W. Portanto, de acordo com este circuito:

$$T_j - T_a = P_{dis}(R_{jC} + R_{CD} + R_{Da}) \quad (19)$$

onde P_{dis} é a potência dissipada pelo componente semicondutor.

Antes de calcular a resistência térmica do dissipador, os seguintes pontos são considerados:

- Os semicondutores S_1 , S_2 e D_1 são fixados no mesmo dissipador de calor;
- Os dois transistores nunca vão conduzir de forma concomitante.

Assim sendo, o projeto térmico é calculado com base no braço responsável pela conexão com o inversor, onde ocorre a maior dissipação de calor. O diodo D_1 (DSEP30-12A) e o transistor S_1 (IHW20N120R3) possuem a temperatura máxima de operação de 175 °C, então $T_j = 175$ °C. Ao considerar a corrente nominal da série FV como 8,5 A, a potência dissipada em D_1 é de aproximadamente 13,6 W e em S_1 de 14,5 W, então $P_{dis} = 28,1$ W.

O projeto desse módulo comutador foi realizado para uma série fotovoltaica com potência nominal de 6,48 kW. Logo, a energia dissipada (28,1 W) equivale à cerca de 0,43% da geração. Vale destacar que essa perda pode ser economizada ao utilizar um circuito composto por um contator em paralelo com o transistor, conforme a chave seccionadora que foi proposta por Zhao, Bhavaraju e Theisen (2015). A escolha pelo contator implica na necessidade de maior espaço físico para acondicionar os módulos comutadores. No caso deste trabalho, optou-se pelo circuito sem o contator.

Ao considerar que os protótipos serão instalados em um painel elétrico localizado no eletrocentro da usina, cujo ambiente é climatizado, definiu-se a temperatura ambiente como 40 °C. A equação (19) modificada para o caso dos módulos comutadores é:

$$T_j - T_a = P_{dis}(R_{jC_{D_1}} + R_{jC_{S_1}} + 2 \cdot R_{CD} + R_{Da}) \quad (20)$$

onde, $R_{jC_{D_1}}$ é resistência térmica entre a junção e o encapsulamento para o diodo D_1 . $R_{jC_{S_1}}$ possui o mesmo significado, mas para o transistor S_1 . Ambos os semicondutores utilizam o encapsulamento TO-247 e são isolados do dissipador através de mica com o uso de pasta térmica. Portanto, a resistência térmica entre o componente e o dissipador (R_{CD}) foi dobrada e considerada como $0,5 \text{ }^\circ\text{C/W}$. Logo,

$$\begin{aligned} T_j - T_a &= P_{dis} \cdot (R_{jC_{D_2}} + R_{jC_{S_2}} + 2 \cdot R_{CD} + R_{Da}) \\ 175 - 40 &= 28,1 \cdot (0,9 + 0,48 + 2 \cdot 0,5 + R_{Da}) \\ R_{Da} &\leq 2,43 \text{ }^\circ\text{C/W} \end{aligned} \quad (21)$$

Conclui-se que a resistência térmica do dissipador com o ambiente deve ser inferior a $2,43 \text{ }^\circ\text{C/W}$. Além disso, para fins de aplicação prática, a estrutura do dissipador deve permitir a fixação do módulo comutador na caixa de junção da usina. O modelo escolhido foi o RDD 9555-100, produzido pela Rei dos Dissipadores, o qual possui a resistência térmica de aproximadamente $1,34 \text{ }^\circ\text{C/W}$. Vale destacar que, caso os módulos comutadores sejam instalados no interior das caixas de junção, o cálculo térmico deve ser reprojeto a partir de uma temperatura ambiente adequada à situação.

Para garantir a dissipação térmica e preservar a vida útil dos semicondutores, optou-se por adicionar um circuito de ventilação forçada, o qual é composto por um ventilador e um sensor de temperatura do tipo NTC. No entanto, devido a característica intermitente dos sistemas fotovoltaicos, o acionamento deste ventilador ocorre através de um circuito do tipo liga-desliga, ou seja, o ventilador entra em operação apenas nos períodos críticos para a dissipação térmica por condução. Para o acionamento do ventilador foi utilizado um Mosfet do modelo AO3400.

Neste trabalho, os módulos comutadores foram construídos para serem fixados, através de seus respectivos dissipadores de calor, no painel elétrico que fica localizado no eletrocentro de uma usina fotovoltaica. A placa eletrônica de cada módulo comutador possui as dimensões de $10 \text{ cm} \times 10 \text{ cm}$. O protótipo de um módulo comutador é mostrado na Figura 27.

Figura 27 – Protótipo do módulo comutador.



(a) Vista superior do módulo comutador.

(b) Vista inferior do módulo comutador.

Fonte: Elaborada pelo autor (2022).

3.2 MÓDULO PARA AQUISIÇÃO DAS CURVAS I-V

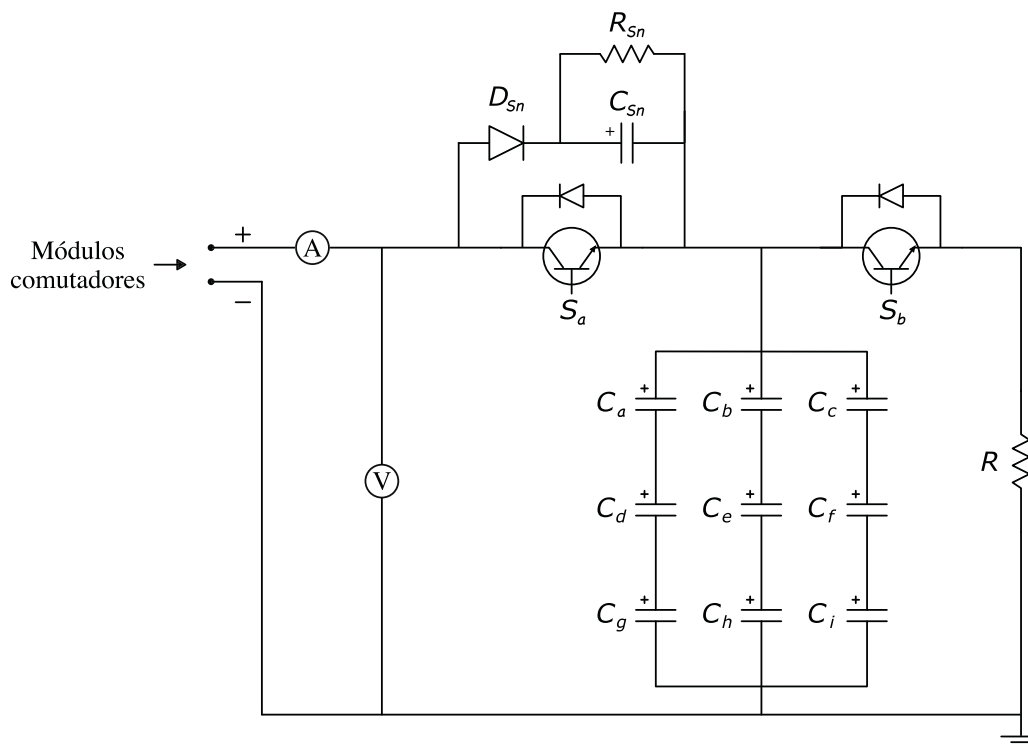
A aquisição das curvas I-V de geradores fotovoltaicos pode ser realizada de diferentes formas, os métodos de destaque são aqueles que fazem uso das cargas: resistiva, capacitiva e eletrônica. No caso do traçador de curvas I-V proposto, tem-se o objetivo de rastrear as curvas de séries fotovoltaicas. Logo, devido à alta potência, optou-se pelo projeto de um traçador com carga capacitiva.

Os capacitores oferecem um caminho de baixa resistência durante o carregamento e um caminho de resistência infinita após a sua tensão igualar a tensão de circuito aberto da série fotovoltaica. Desta forma, os capacitores permitem traçar a curva I-V de forma natural, precisa, automática e com baixa ondulação na tensão e na corrente. A topologia do módulo proposto para aquisição das curvas I-V é mostrada na Figura 28 e a sua operação pode ser dividida em duas etapas, sendo elas:

Etapa I o transistor S_b para de conduzir e o transistor S_a entra em condução. Nesse instante, a curva I-V começa a ser rastreada. Enquanto o banco de capacitores é carregado, o circuito move-se de I_{sc} para V_{oc} e, através dos sensores de corrente e tensão, os pontos da curva I-V são registrados.

Etapa II ao final da primeira etapa, o transistor S_a para de conduzir e o transistor S_b entra em condução. Assim, o banco de capacitores é descarregado e o traçador de curvas encontra-se pronto para uma nova medição.

Figura 28 – Topologia do módulo para aquisição de curvas I-V.



Fonte: Elaborada pelo autor (2022).

Os traçadores de curvas I-V que utilizam carga capacitiva exigem que os capacitores sejam previamente carregados com tensão negativa para que o ponto coordenado da corrente de curto-circuito ($0; I_{sc}$) possa ser mensurado. No caso do traçador proposto optou-se pela alternativa de extrapolar o valor de I_{sc} , o que implica em assumir que a perna horizontal da curva I-V é uma reta. Assim sendo, o traçador utiliza o primeiro ponto mensurado e o ponto equivalente à 10% da tensão de circuito aberto para determinar a equação de uma reta. Essa equação possibilita que o ponto ($0; I_{sc}$) seja estimado.

O projeto do módulo para aquisição das curvas I-V pode ser dividido em: circuito de sensoriamento, circuito operacional, carga capacitiva e circuito de processamento. A seguir, o projeto de cada um destes circuitos é apresentado.

3.2.1 Circuito de sensoriamento

O circuito de sensoriamento é responsável pela medição dos parâmetros elétricos da curva I-V. Uma visão geral das entradas e saídas deste circuito é mostrada no diagrama da Figura 29. Trata-se do circuito de entrada do módulo para aquisição das curvas I-V. Logo, os cabos de potência que provém dos módulos comutadores passam pelos sensores de corrente e tensão e seguem para o circuito operacional.

Figura 29 – Diagrama de entradas e saídas do circuito de sensoriamento.



Fonte: Elaborada pelo autor (2022).

A medição da corrente elétrica é realizada pelo sensor LAH 25-NP, produzido pela LEM, o qual possui precisão nominal de $\pm 0,3\%$. O sensor possibilita a medição da corrente elétrica com valores nominais de 8 A, 12 A ou 25 A, dependendo da configuração escolhida. No caso, optou-se pela configuração de 12 A, o que implica em uma corrente no lado secundário de 24 mA.

A medição da tensão elétrica é realizada pelo sensor LV 25-P/SP5, produzido pela LEM, o qual possui precisão nominal de $\pm 0,8\%$. O sensor pode medir até 1.500 V, em corrente contínua, sendo que a entrada se dá em corrente com o valor nominal de 10 mA. Enquanto a saída, também em corrente, possui o valor nominal de 25 mA.

O ensaio para calibração do circuito de sensoriamento foi realizado em laboratório e empregou uma carga resistiva, o simulador fotovoltaico N8957APV fabricado pela Keysight e o analisador de potência LMG670 fabricado pela Zimmer. O LMG670 permite mensurar a corrente e a tensão com a precisão de $\pm 0,02\%$ da leitura e $\pm 0,08\%$ do fundo da escala.

Os ajustes e as calibrações das medições de corrente e tensão são realizados no processador do traçador de curvas I-V. Os resultados nesse processo são mostrados nas Tabelas 8 e 9, respectivamente. A placa eletrônica do circuito de sensoriamento é mostrada na Figura 30.

Tabela 8 – Resultado do processo de calibração e ajuste do circuito para medição da corrente.

Protótipo (A)	LMG670 (A)	Erro (A)	Erro (%)
1,02	1,07	0,048	4,73%
2,03	2,07	0,041	2,03%
3,04	3,05	0,013	0,44%
4,05	4,06	0,013	0,33%
5,09	5,05	-0,043	-0,85%
6,16	6,13	-0,032	-0,53%
7,12	7,07	-0,049	-0,69%
8,13	8,07	-0,060	-0,74%
9,14	9,06	-0,077	-0,85%
10,15	10,05	-0,103	-1,01%


Fonte: Elaborada pelo autor (2022).

Tabela 9 – Resultado do processo de calibração e ajuste do circuito para medição da tensão.

Protótipo (V)	LMG670 (V)	Erro (V)	Erro (%)
99,07	100,1	1,03	1,04%
198,85	200,1	1,25	0,63%
299,22	300,1	0,88	0,29%
399,69	400,1	0,41	0,10%
502,73	500,4	-2,33	-0,46%
604,20	600,3	-3,90	-0,65%
708,37	700,6	-7,77	-1,10%
812,60	800,8	-11,80	-1,45%
919,30	900,8	-18,50	-2,01%
1026,5	1001,4	-25,15	-2,45%

Fonte: Elaborada pelo autor (2022).

Figura 30 – Placa eletrônica do circuito de sensoriamento.



Fonte: Elaborada pelo autor (2022).

3.2.2 Circuito operacional

O circuito operacional realiza a conexão da série fotovoltaica com a carga capacitiva e também atua na descarga do banco de capacitores. Uma visão geral das entradas e saídas deste circuito é mostrada no diagrama da Figura 31. O circuito operacional é composto pelos

transistores S_a e S_b , além de seus respectivos circuitos de comando. Sendo que o sinal de comando para os transistores é gerado pelo circuito de processamento.

Figura 31 – Diagrama de entradas e saídas do circuito operacional.



Fonte: Elaborada pelo autor (2022).

O transistor S_a é responsável pela conexão da série fotovoltaica com a carga capacitiva e S_b controla a descarga do banco de capacitores. Posto isto e considerando a topologia proposta para os módulos comutadores, percebe-se que a conexão da série fotovoltaica com a carga capacitiva apresenta dois transistores em série, o transistor S_2 localizado no módulo comutador e o transistor S_a no circuito operacional. A necessidade de S_a justifica-se pelo fato de que um atraso na comunicação com o módulo comutador causaria uma perda de sincronismo entre o instante de conexão da série FV com a carga capacitiva e o início da aquisição dos parâmetros elétricos. Essa falha de sincronismo implicaria em perdas no registro dos parâmetros elétricos.


Teoricamente, o transistor S_a nunca é comutado sob carga, pois no momento de sua desconexão, os capacitores já estão carregados e o circuito encontra-se na condição de circuito aberto. Contudo, no traçador de curvas proposto, a medição da curva I-V é realizada em um período fixo. Logo, em situações de significativo sombreamento, os capacitores ainda podem estar sendo carregados no instante de desconexão da série fotovoltaica. Assim sendo, a presença de uma corrente elétrica residual somada a característica indutiva da série FV causaria sobretensões no transistor. Portanto, o transistor S_a foi projetado com o IGBT IHW20N120R3 junto de um circuito de grameamento do tipo RCD que utiliza os mesmos componentes do *snubber* dos módulos comutadores. Em trabalhos futuros, recomenda-se que o valor da corrente seja avaliado previamente com o objetivo de impedir que transistor S_a seja comutado sob carga, o que evita esforços desnecessários nos semicondutores.

Ao final da aquisição de cada curva I-V, o banco de capacitores deve ser descarregado para que uma nova medição possa ser realizada. Essa tarefa ocorre em um circuito composto pelo transistor S_b , modelo IHW20N120R3, e por um resistor de potência de $200 \Omega / 160 \text{ W}$. O dimensionamento desse resistor é realizado conforme a equação (2), a qual determina o tempo mínimo para descarregar a carga capacitiva com segurança. No caso do traçador de curvas proposto, optou-se por garantir o tempo de descarga inferior à 1 segundo. Por fim, destaca-se que o uso de resistores de potência evita o superaquecimento desse componente e possibilita a aquisição de novas curvas I-V em um curto período.

O comando dos transistores S_a e S_b é realizado pelos optoacopladores TLP250. A placa eletrônica do circuito operacional foi fixada em um dissipador de calor do modelo RDD 9555-100,

conforme mostra a Figura 32.

Figura 32 – Placa eletrônica do circuito operacional.



Fonte: Elaborada pelo autor (2022).

3.2.3 Carga capacitiva

Um aspecto essencial do projeto de traçadores de curvas I-V está no dimensionamento da carga capacitiva, pois o tempo necessário para aquisição de uma curva I-V depende da capacitância projetada. Vale relembrar que, as curvas adquiridas em um curto período podem sofrer oscilações devido as características indutivas e capacitivas das séries fotovoltaicas. Assim como, as curvas adquiridas durante um período demasiadamente longo podem sofrer oscilações nas condições climáticas. Portanto, sugere-se que o rastreamento ocorra em cerca de 100 ms.

A carga capacitiva do traçador de curvas I-V foi projetada com a capacitância de $820 \mu\text{F}$. De acordo com a equação (1), uma série FV com $V_{oc} = 900 \text{ V}$ e $I_{sc} = 9 \text{ A}$ terá a sua curva I-V rastreada em aproximadamente 82 ms. No entanto, o resultado dessa equação é aproximado, pois ela estima a condutância média e não considera o período no qual o circuito está próximo de V_{oc} , onde a corrente diminui e eleva o tempo final de carga. Além disso, o tempo de carga também é acrescido devido aos parâmetros da equação estarem na STC, o que não representa as condições climáticas do dia-a-dia. Portanto, devido às circunstâncias supracitadas e ao fato do traçador de curvas I-V proposto realizar a medição das curvas em um período fixo, optou-se por ajustar o período de aquisição para 250 ms, onde são adquiridos 500 pontos coordenados.

Salienta-se que, o mercado dispõem de várias tecnologias de capacitores e geralmente a escolha por uma ou outra se dá em virtude do tipo de tarefa a ser executada. No caso de

traçadores de curvas I-V existe a preferência pelos capacitores eletrolíticos, os quais possuem boa resposta em baixa frequência e baixa resistência série equivalente (SAYYAD; NASIKKAR, 2021).

Por fim, sugere-se que a faixa de tensão máxima da carga capacitiva seja 20% maior que a tensão de circuito aberto do dispositivo fotovoltaico a ser ensaiado. Assim sendo, no protótipo do traçador de curvas I-V optou-se por um arranjo série-paralelo com nove capacitores de 450 V, o que resultou em um carga capacitiva de $820 \mu\text{F} / 1.350 \text{ V}$. A placa eletrônica da carga capacitiva é mostrada na Figura 33.

Figura 33 – Placa eletrônica da carga capacitiva.



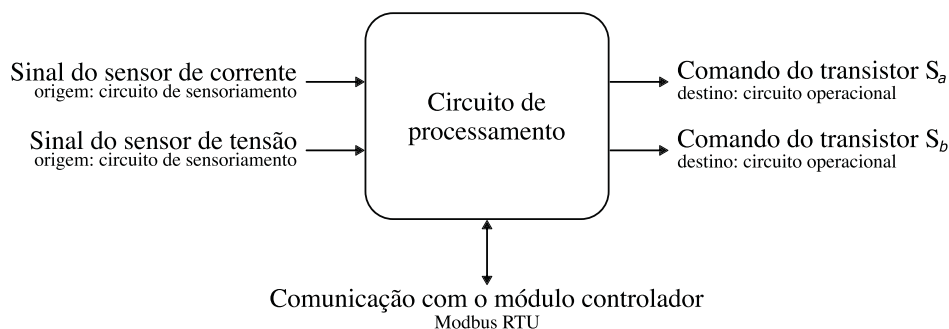
Fonte: Elaborada pelo autor (2022).

3.2.4 Circuito de processamento

O circuito de processamento realiza o gerenciamento do módulo para aquisição de curvas I-V. Uma visão geral das entradas e saídas deste circuito é mostrada no diagrama da Figura 34. As tarefas executadas por este circuito englobam a comunicação com o módulo controlador, o comando dos transistores S_a e S_b e o condicionamento dos sinais provenientes dos sensores de corrente e tensão.

O circuito de processamento foi projetado com o microcontrolador ESP-32, o qual foi escolhido devido a maior capacidade de processamento se comparado ao ATmega328p. O ESP-32 possui um microprocessador de 32 bits com dois núcleos e pode operar em uma frequência de até 240 MHz. Além disso, possui 18 pinos com capacidade de ler sinais analógicos através de dois conversores A/D com resolução de 12 bits. No entanto, estes conversores não possuem

Figura 34 – Diagrama de entradas e saídas do circuito de processamento.



Fonte: Elaborada pelo autor (2022).


um bom rendimento e podem ser insuficientes para algumas aplicações, conforme mostram os resultados de Morais (2019).

O circuito de sensoriamento é responsável pela medição dos parâmetros elétricos da curva I-V (corrente e tensão). Enquanto o circuito de processamento realiza a leitura dos sinais analógicos provenientes dos sensores e os converte para a forma digital. No entanto, conforme já citado, o microcontrolador ESP-32 não possui conversores A/D de alta qualidade, o que pode degradar significativamente a medição das curvas I-V. Assim sendo, optou-se pelo projeto de dois módulos externos, um para conversão A/D da corrente e outro para conversão A/D da tensão. Vale destacar que o uso de dois módulos A/D possibilita que a medição dos parâmetros elétricos ocorra de forma paralela.

Os módulos para conversão A/D foram projetados com o microcontrolador ATmega328p e com o conversor ADS1256. Este conversor possui 24 bits de resolução e a capacidade de adquirir 30 mil amostras por segundo. Destaca-se a importância da alta resolução para garantir a qualidade das medições realizadas. Além da necessidade de uma taxa de aquisição elevada devido ao curto período no qual ocorre o carregamento da carga capacitiva e a necessidade de rastrear a maior quantidade possível de pontos da curva I-V.

A interface entre o conversor ADS1256 e o microcontrolador ATmega328p ocorre via SPI e os parâmetros registrados pelos módulos A/D são transferidos para o microcontrolador ESP-32 através do barramento UART. A placa eletrônica de um dos módulos que foi projetado para a conversão A/D é mostrada na Figura 35a. Enquanto a placa do circuito de processamento é mostrada na Figura 35b, onde percebe-se a conexão dos módulos A/D e de um módulo de comunicação RS-485. Além disso, vale mencionar a necessidade de um circuito conversor de nível lógico, pois o ATmega328p é alimentado em 5 V e o ESP-32 em 3,3 V.

Figura 35 – Circuito de processamento do módulo para aquisição das curvas I-V.



(a) Módulo para conversão A/D.

(b) Placa do circuito de processamento.

Fonte: Elaborada pelo autor (2022).

O circuito de processamento é responsável por gerenciar todas as atividades que englobam a aquisição das curvas I-V, conforme mostra o fluxograma da Figura 36. No entanto, a aquisição de uma nova curva I-V só inicia mediante o recebimento de um comando procedente do módulo controlador, via Modbus RTU.

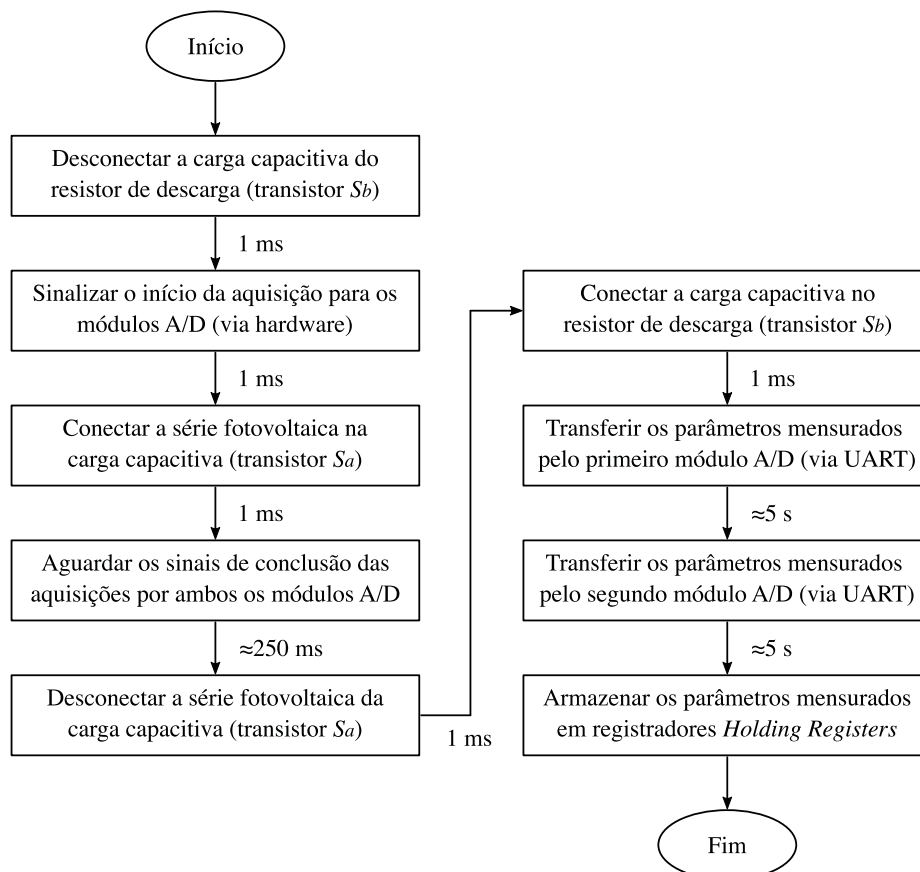
Em um primeiro momento, ao receber o comando para iniciar a aquisição de uma curva I-V, a carga capacitiva é desconectada do resistor de descarga pelo transistor S_b . A seguir, um comando do ESP-32 para ambos os módulos A/D, via hardware, sinaliza o início da aquisição dos parâmetros elétricos. Após, a série fotovoltaica é conectada na carga capacitiva pelo transistor S_a . Vale destacar a existência de um intervalo de 1 ms entre os comandos. Portanto, é possível perceber que o início da aquisição dos parâmetros elétricos ocorre cerca de 1 ms antes da conexão da série fotovoltaica com a carga capacitiva, o que permite mensurar a tensão de circuito aberto da série fotovoltaica.

A aquisição da curva I-V, conforme descrito anteriormente, é realizada em um período de 250 ms, onde são adquiridos os 500 pontos coordenados da curva I-V. Ao finalizar a aquisição dos parâmetros elétricos, cada um dos módulos A/D envia um sinal de conclusão para o ESP-32, via hardware. Ao receber ambos os sinais de conclusão, o ESP-32 realiza a desconexão da série fotovoltaica com a carga capacitiva (transistor S_a) e, em seguida, ocorre a conexão banco de capacitores no resistor de descarga (transistor S_b).

Posteriormente, realiza-se a transferência para o ESP-32 dos 500 pontos de corrente elétrica registrados por um módulo A/D, o que ocorre através do barramento UART. Logo depois, os 500 pontos de tensão elétrica são transferidos do segundo módulo A/D para o ESP-32. A transferência dos registros de cada módulo A/D demora cerca de 5 segundos. Por fim, esses

1.000 registros são armazenados em registradores do tipo *Holding Registers* e podem ser lidos pelo módulo controlador, via Modbus RTU. Pela alta quantidade de informações que devem ser trafegadas pelo barramento RS-485, um dos núcleos do ESP-32 foi alocado apenas para as tarefas de comunicação. A partir desse momento, o traçador de curvas I-V encontra-se disponível para realizar a aquisição de uma nova curva I-V.

Figura 36 – Fluxograma do algoritmo do circuito de processamento do traçador de curvas I-V.




Fonte: Elaborada pelo autor (2022).

3.2.5 Integração dos circuitos que compõem o módulo para aquisição das curvas I-V

Os protótipos que foram desenvolvidos e integram o módulo para aquisição das curvas I-V foram montados em uma caixa de passagem com as dimensões de 384 mm x 304 mm x 120 mm. A integração destes circuitos é mostrada na Figura 37. Vale apontar que por questões de dissipação térmica, o resistor para descarga do banco de capacitores não fica alojado nesta mesma caixa.

Figura 37 – Protótipo do módulo para aquisição das curvas I-V.



Fonte: Elaborada pelo autor (2022).

3.3 MÓDULO PARA AQUISIÇÃO DOS PARÂMETROS CLIMÁTICOS

A medição de uma curva I-V sempre deve vir acompanhada das condições climáticas do ambiente circundante a matriz no instante do ensaio. Assim sendo, propõem-se um módulo para a medição da irradiância no plano inclinado e da temperatura de operação dos módulos fotovoltaicos. A seguir, o projeto destes circuitos são apresentados.

3.3.1 Medição da irradiância no plano inclinado


Ao medir a irradiância no plano inclinado, está se quantificando a entrada de energia do arranjo fotovoltaico. Assim sendo, trata-se de uma das medições mais importantes de ser realizada. No entanto, ao contrário da medição de temperatura, os instrumentos utilizados nesse processo não são tão populares. Em geral, a medição da irradiância é realizada através de células de referência ou de piranômetros.

No caso do módulo proposto empregou-se a célula de referência Si-I-420-T que é produzida pela Meteo Control. A célula é capaz de medir a faixa de 0 W/m^2 até 1.500 W/m^2 com a incerteza de $\pm 5 \text{ W/m}^2 \pm 2,5\%$ da leitura. A saída da célula se dá em corrente com um sinal de 4 mA a 20 mA proporcional a irradiância. Vale destacar que a Si-I-420-T possui um sensor de temperatura na superfície traseira da célula e realiza a compensação ativa da temperatura, o que reduz a influência da temperatura no sinal de medição da irradiação.

O circuito projetado possui um microcontrolador ATmega328p, sendo este responsável pela medição da irradiância e por transferir, quando solicitado, os registros para o módulo controlador, via Modbus RTU. O ATmega328p, assim como o ESP-32, não possui um conversor A/D de alta qualidade, então optou-se pelo uso do ADS-1220, sendo este um conversor com 24 bits de resolução e a capacidade de adquirir 2.000 amostras por segundo. A medição da irradiância não exige um conversor A/D com alta taxa de aquisição, pois ela é mensurada apenas no início e no final da aquisição de cada curva I-V. A medição inicial serve para verificar o nível mínimo de irradiância necessário para a execução do ensaio, enquanto a medição no final possibilita checar se a irradiância variou significativamente durante a aquisição da curva I-V. A troca de informações entre o ADS-1220 e o ATmega328p é realizada através da interface SPI. A placa eletrônica projetada para este circuito é mostrada na Figura 38.

A calibração e o ajuste do circuito proposto ocorreu através da comparação entre a irradiância mensurada pelo protótipo e a irradiância mensurada pelo módulo SolSensor, conforme mostra a Figura 39. O SolSensor é um módulo para medições de parâmetros climáticos que acompanha o traçador de curvas I-V produzido pela Solmetric e possui a precisão de $\pm 2\%$ para uma leitura de até 1.500 W/m^2 . Os resultados que foram obtidos nesse processo são apresentados na Tabela 10.

Figura 38 – Placa eletrônica do circuito para medição da irradiância no plano inclinado.



Fonte: Elaborada pelo autor (2022).

Figura 39 – Ensaio para calibração e ajuste do circuito para medição da irradiância no plano inclinado.



Fonte: Elaborada pelo autor (2022).

Tabela 10 – Resultado do processo de calibração e ajuste do circuito para medição da irradiância no plano inclinado.

Protótipo (W/m ²)	SolSensor (W/m ²)	Erro (W/m ²)	Erro (%)
605,13	610	-4,869	-0,80
706,61	710	-3,387	-0,48
798,69	800	-1,302	-0,16
913,33	910	3,335	0,37
1.021,39	1020	1,394	0,14

Fonte: Elaborada pelo autor (2022).

3.3.2 Medição da temperatura de operação dos módulos fotovoltaicos

A medição da temperatura de operação dos módulos fotovoltaicos pode ser realizada por contato (sensor fixado no módulo), sem contato (câmera infravermelha) ou de forma indireta (análise da tensão de circuito aberto). No caso do circuito proposto, optou-se pela medição por contato devido as facilidades de implementação e pelos resultados satisfatórios que esse método pode entregar. Em relação a tecnologia do sensor, empregou-se uma termorresistência PT-100 de classe C com medição à dois fios.


O PT-100 é um sensor amplamente utilizado no meio industrial, cujo princípio de funcionamento ocorre pela variação da resistência elétrica em função da temperatura. De forma aproximada, a relação entre a resistência e a temperatura pode ser determinada por:

$$R_T(t) = R_0(1 + a_r \cdot T) \quad (22)$$

onde R_T é a resistência elétrica medida, em Ω . R_0 é a resistência elétrica à temperatura de 0 °C, em Ω . No caso do PT-100, $R_0 = 100 \Omega$. a_r é o coeficiente de variação da resistência elétrica em função da temperatura, em °C. T é a temperatura, em °C.

Novamente, decidiu-se pelo uso de um microcontrolador ATmega328p, sendo este responsável pela medição da temperatura e por transferir, quando solicitado, os registros para o módulo controlador, via Modbus RTU. A interface entre a termorresistência e o microcontrolador foi realizada através do conversor digital de resistência MAX31865, o qual é projetado para a leitura de termorresistências e converte automaticamente o valor da resistência para o formato digital. O MAX31865 possui um conversor A/D de 15 bits com precisão de $\pm 0,5$ °C e a interface com o microcontrolador ocorre via SPI. Assim como ocorre na medição da irradiância, a temperatura é mensurada apenas no início e no final da aquisição de cada curva I-V, o que permite verificar se houve uma variação significativa da temperatura durante o ensaio. A placa eletrônica projetada para o circuito de medição da temperatura de operação dos módulos é mostrada na Figura 40.


Figura 40 – Placa eletrônica do circuito para medição da temperatura de operação dos módulos.



Fonte: Elaborada pelo autor (2022).

A calibração e o ajuste do circuito ocorreu através da comparação entre a temperatura mensurada pelo protótipo e a temperatura mensurada pelo módulo SolSensor. Ambos os sensores foram fixados na parte traseira de um módulo fotovoltaico, em uma posição representativa da temperatura média da matriz, conforme mostra a Figura 41. O módulo SolSensor possui uma precisão de ± 2 °C e os resultados obtidos na calibração são apresentados na Tabela 11.

Figura 41 – Ensaio para calibração e ajuste do circuito para medição da temperatura de operação dos módulos.



Fonte: Elaborada pelo autor (2022).

Tabela 11 – Resultado do processo de calibração e ajuste do módulo para medição da temperatura de operação dos módulos.


Protótipo (°C)	SolSensor (°C)	Erro (°C)	Erro (%)
19,2	19,0	-0,170	-0,89
34,8	34,6	-0,220	-0,63
41,3	41,7	-0,360	-0,87

Fonte: Elaborada pelo autor (2022).

3.3.3 Integração dos circuitos que compõem o módulo para aquisição dos parâmetros climáticos

Os protótipos que foram desenvolvidos e integram o módulo para aquisição dos parâmetros climáticos foram montados em uma caixa de passagem com as seguintes dimensões: 170 mm x 145 mm x 90 mm. A integração destes circuitos é mostrada na Figura 42. Destaca-se que esse módulo é instalado junto da matriz fotovoltaica e por isso foi escolhida uma caixa com proteção IP65.

Figura 42 – Protótipo do módulo para aquisição dos parâmetros climáticos.



Fonte: Elaborada pelo autor (2022).

3.4 MÓDULO CONTROLADOR

O traçador de curvas I-V, conforme descrito, é composto pelos módulos comutadores, o módulo para aquisição das curvas I-V e o módulo para aquisição dos parâmetros climáticos. Vale ressaltar que todos esses dispositivos devem operar de forma síncrona para que as curvas sejam corretamente adquiridas e registradas. Logo, cabe ao módulo controlador gerenciar esse processo e armazenar as curvas I-V mensuradas.

O controlador é projetado através de uma placa Raspberry Pi 4, a qual é um pequeno computador com entradas e saídas (E/S) digitais. A escolha pela Raspberry justifica-se pelo seu baixo custo se comparado aos computadores tradicionais, pelas dimensões reduzidas, pela capacidade de processar linguagens de programação de alto nível e pela presença de E/S digitais.

A estrutura do módulo controlador é composta por um circuito para condicionamento da alimentação da Raspberry e por um conversor USB/RS-485 que permite o acesso ao barramento de comunicação. Esses dispositivos foram integrados em uma caixa de passagem com as dimensões de 170 mm x 145 mm x 90 mm, conforme mostra a Figura 43.

Figura 43 – Protótipo do módulo controlador.



Fonte: Elaborada pelo autor (2022).

A Raspberry utiliza o sistema operacional Raspberry Pi OS, o qual é baseado na distribuição Debian e desenvolvido pela própria fabricante. O sistema operacional, assim como os demais softwares da Raspberry, ficam armazenados em um cartão de memória do tipo microSD, sendo possível o uso de cartões com a capacidade de até 2 TB. As curvas I-V mensuradas também são registradas nesse mesmo cartão, sendo que cada curva ocupa cerca de 50 kB. Logo, o quantitativo de curvas I-V que podem ser armazenadas internamente depende da capacidade do cartão de memória utilizado. O gerenciamento do espaço livre e a exclusão das curvas mais antigas deve ser realizado de forma manual pelo operador.

O gerenciamento dos módulos que compõem o traçador de curvas I-V é realizado através do pacote de serviços LAMP, um acrônimo para Linux (sistema operacional), Apache (servidor Web), MySQL (banco de dados) e PHP/Python (linguagens de programação). Esse pacote de serviços foi uma das primeiras soluções de software livre para a internet e ainda é uma das formas mais comuns de desenvolver aplicativos para a web. Trata-se de uma solução estável, simples e potente.

No caso do traçador de curvas I-V, o pacote LAMP possibilita ao operador acessar remotamente os parâmetros mensurados e ajustar as especificações técnicas que são necessárias para a realização dos ensaios, tais como: a irradiância mínima para a aquisição de uma curva I-V (G_{min}), a variação máxima tolerável da temperatura (T_{var}) e da irradiância (G_{var}) durante o ensaio, além de definir um vetor que identifica quais as séries fotovoltaicas que serão ensaiadas (*serieFV*). O ajuste dessas especificações pode tomar como base as seguintes premissas:

Irradiância mínima: a Norma IEC 62446-1 estabelece que o ensaio deve ser realizado com a irradiância mínima de 400 W/m^2 medida no plano dos módulos fotovoltaicos. Enquanto a Norma IEC 60904-1 estabelece que no caso de conversão das curvas para a STC, o ensaio deve ser realizado com a irradiância mínima de 800 W/m^2 .

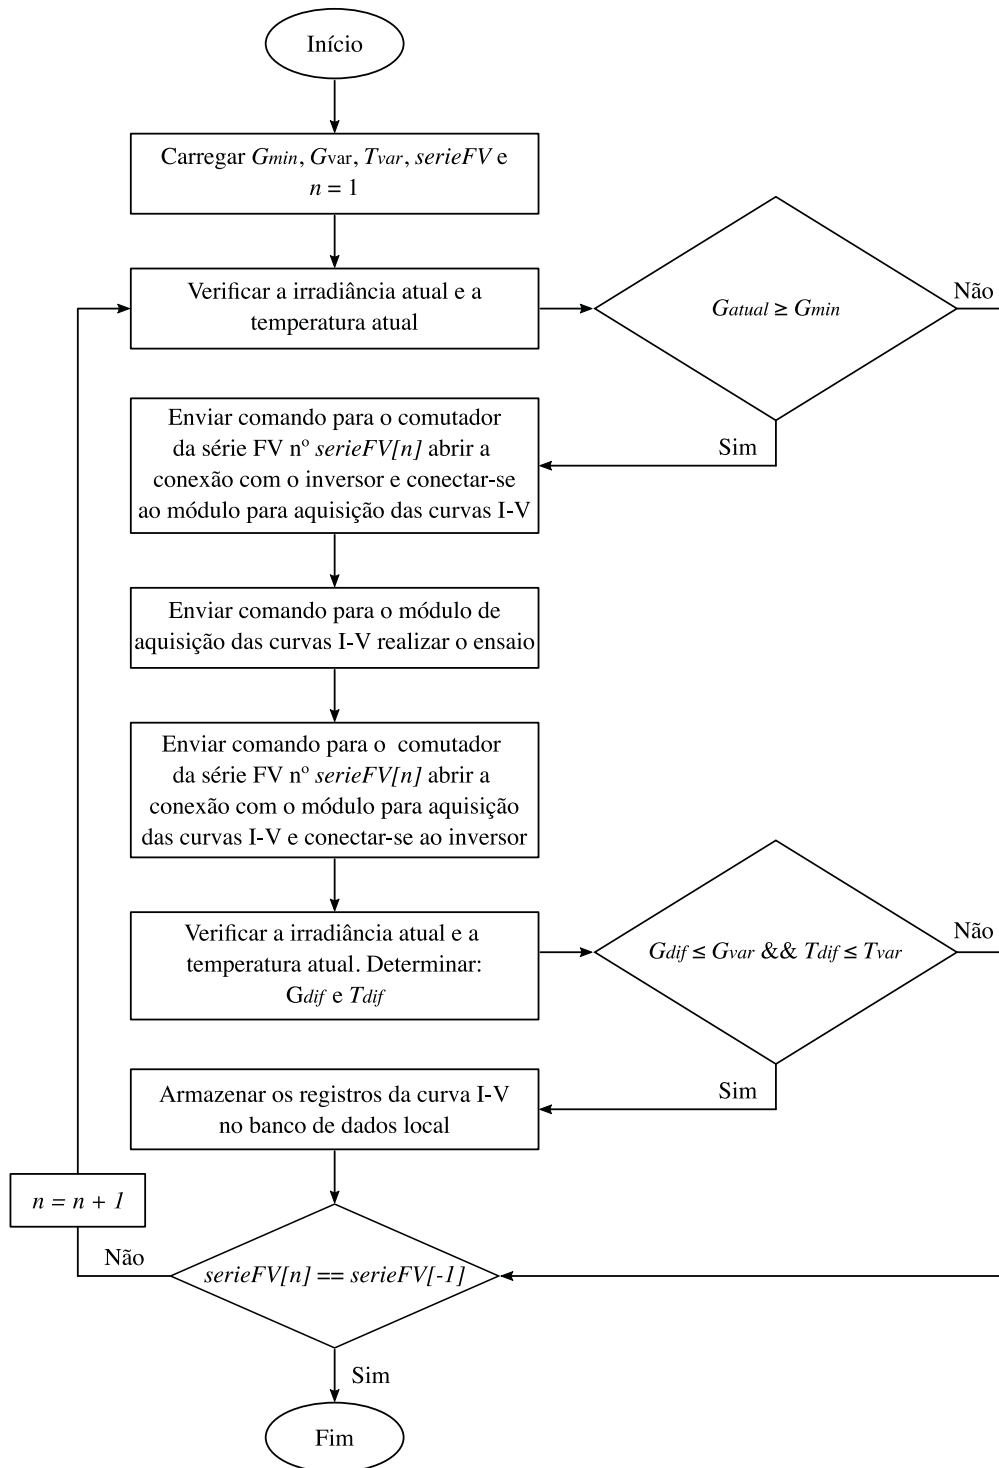
Estabilidade dos parâmetros climáticos: a Norma IEC 60904-1 estabelece que a temperatura dos módulos deve permanecer estável dentro de $\pm 1 \text{ }^\circ\text{C}$ durante o ensaio. Já a irradiância solar global não deve flutuar por mais de $\pm 1\%$ durante a medição.

A operação do traçador de curvas I-V ocorre através de duas aplicações desenvolvidas em Python, uma para controlar a execução dos ensaios e outra para a troca de informações com o servidor remoto. Ambas são programadas como um *Cron Job* para serem executadas a cada hora. Destaca-se que, em um sistema Linux, o *Cron* é uma aplicação que permite executar tarefas repetidamente em uma data futura.

A aplicação que controla a execução dos ensaios, conforme ilustra a Figura 44, é responsável pelos seguintes passos:

1. Carregar as especificações da irradiância, da temperatura e das séries fotovoltaicas a serem ensaiadas (G_{min} , T_{var} , G_{var} e *serieFV*);

Figura 44 – Fluxograma da aplicação que controla a execução dos ensaios.



Fonte: Elaborada pelo autor (2022).

2. Enviar o comando para medição da temperatura e da irradiância. Caso a irradiância medida (G_{atual}) seja inferior ao mínimo especificado (G_{min}), então avança para a Etapa 8. Caso contrário, avança para a Etapa 3;
3. Enviar o comando ao módulo comutador para desconectar a série FV do inversor e conectar no traçador de curvas;
4. Enviar o comando ao módulo de aquisição das curvas I-V para a realização do ensaio;
5. Enviar o comando ao módulo comutador para desconectar a série FV do traçador de curvas e conectar no inversor;
6. Enviar o comando para medição da temperatura e da irradiância. Calcular a variação dos parâmetros climáticos durante o ensaio. Se algum parâmetro variar acima do limite especificado (T_{var} e G_{var}), então avança para a Etapa 8. Caso contrário, avança para a Etapa 7;
7. Registrar a curva I-V no banco de dados interno da Raspberry;
8. Finaliza o ensaio da série FV atual ($serieFV[n]$) e inicializa o ensaio da próxima série ($serieFV[n + 1]$). Contudo, se a série em análise for a última do arranjo ($serieFV[-1]$), então o ensaio é finalizado e aguarda-se por uma nova chamada do *Cron Job*.

A segunda aplicação é responsável pela troca de informações com um servidor remoto, sendo esse localizado na nuvem ou no próprio local da usina. As atividades desempenhadas por essa aplicação são as seguintes:

Espelhamento das curvas I-V os registros que estão contidos no banco de dados local são comparados com aqueles que estão no banco de dados remoto, no caso de houver o registro de alguma curva I-V apenas no banco local, então ocorre o espelhamento dessas informações para o banco remoto. Vale ressaltar que as curvas espelhadas continuam armazenadas no banco local e só podem ser excluídas manualmente pelo operador.

Espelhamento das especificações técnicas o operador é responsável por configurar no banco de dados remoto as especificações técnicas para a realização dos ensaios, tais como: G_{min} , T_{var} , G_{var} e $serieFV$. Logo, cabe a aplicação espelhar essas informações do banco de dados remoto para o banco local sempre que houver alterações.

Por fim, enfatiza-se que o espelhamento entre os bancos de dados, um local e outro remoto, agrega algumas vantagens interessantes ao traçador de curvas I-V, sendo elas:

- Acesso remoto as curvas I-V mensuradas;
- Possibilidade de modificar remotamente as especificações técnicas que são necessárias para a execução dos ensaios;

- Redução na necessidade de deslocamento das equipes de O&M para avaliar o desempenho de usinas fotovoltaicas;
- Continuidade dos ensaios mesmo em situações de falha da conexão com a Internet;
- Maior segurança, a cópia local do banco de dados evita que uma fatalidade ou um ataque cibernético possa acarretar na perda de registros.

3.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Esse capítulo apresentou uma das principais contribuições da tese: o projeto de um traçador de curvas I-V integrado à usinas fotovoltaicas. Trata-se de um equipamento para auxiliar nas tarefas de monitoramento e diagnóstico da geração fotovoltaica de usinas. Destaca-se, a possibilidade de medir automaticamente as curvas I-V de cada uma das séries FV e acessar remotamente os resultados obtidos.

O traçador de curvas I-V proposto é composto pelos módulos: comutadores, aquisição de curvas I-V, aquisição dos parâmetros climáticos e controlador. Ao longo deste capítulo foram expostos os projetos de cada um desses módulos ao considerar uma série fotovoltaica com tensão de circuito aberto de 900 V e corrente de curto-circuito de 9 A

Os módulos comutadores são conectados a cada uma das séries fotovoltaicas e possuem a função de conexão/desconexão da série com o inversor e com o módulo para aquisição das curvas I-V. Em outras palavras, os comutadores determinam o fluxo da corrente elétrica. Sendo que esses processos de conexão/desconexão da série FV são realizados conforme os comandos que são emitidos pelo módulo controlador e recebidos pelos comutadores, via Modbus RTU.

O módulo para aquisição das curvas I-V foi projetado com um banco de capacitores de 820 μF e 1.350 V. Além da carga capacitiva, esse módulo é composto pelos sensores para aquisição dos parâmetros elétricos e por um circuito para descarga dos capacitores. Destaca-se que, teoricamente, a capacitância projetada permite adquirir uma curva I-V em cerca de 82 ms. No entanto, na prática, o tempo de aquisição é maior e definiu-se o período de aquisição em 250 ms, onde são adquiridos 500 pontos coordenados da curva I-V.

O módulo para aquisição dos parâmetros climáticos é responsável por adquirir a irradiância solar no plano inclinado e a temperatura de operação dos módulos fotovoltaicos. A irradiância é mensurada por uma célula de referência, enquanto a medição da temperatura ocorre através de uma termorresistência do tipo PT-100.

Por fim, o módulo controlador foi projetado através de uma placa Raspberry Pi. Esse módulo é responsável por gerenciar o processo de aquisição das curvas I-V, armazená-las internamente e espelhá-las para um banco de dados remoto. Vale destacar que as aquisições são realizadas por uma aplicação executada por um *Cron Job* a cada hora. Sendo o operador responsável por programar a irradiância mínima e a variação máxima tolerável da temperatura e da irradiância para a execução dos ensaios.

4 METODOLOGIA PARA O DIAGNÓSTICO DA GERAÇÃO DE USINAS FV

O diagnóstico de usinas fotovoltaicas possibilita que as equipes de O&M atuem rapidamente no problema e tragam soluções eficazes, o que é essencial para melhorar a confiabilidade e o retorno financeiro desses sistemas. No entanto, o mercado fotovoltaico apesar de oferecer um conjunto de soluções para o monitoramento FV, ainda carece de ferramentas que tenham a capacidade de avaliar e diagnosticar a geração de usinas, o que é essencial para a celeridade das equipes de O&M e, conseqüentemente, para a redução das perdas na geração fotovoltaica.

A metodologia proposta neste trabalho para diagnosticar a geração de usinas fotovoltaicas baseia-se na análise das curvas I-V das séries fotovoltaicas. Através dessas curvas são extraídos alguns indicadores que permitem avaliar o desempenho dos geradores fotovoltaicos ensaiados, tais como: a potência máxima, a corrente de curto-circuito, a tensão de circuito aberto, a corrente e a tensão no ponto de máxima potência.

Os fatores de degradação que afetam o desempenho das séries fotovoltaicas impactam nos indicadores que são extraídos das curvas I-V. Essa característica possibilita que sejam criadas algumas assinaturas para identificar os fatores de degradação e classificar a condição operacional das séries fotovoltaicas.

Por exemplo, a sujidade uniforme dos módulos impede que a irradiação atinja as células fotovoltaicas, o que implica na redução da corrente elétrica da série fotovoltaica. Neste caso, a corrente medida (I_{sc} e I_{mp}) é menor que a corrente estimada pelo modelo matemático para essas mesmas condições climáticas. Por outro lado, o sombreamento parcial ocorre quando certas regiões da matriz são sombreadas, enquanto outras permanecem iluminadas. Neste caso, alguns pontos de inflexão podem aparecer na curva I-V devido à condução de alguns dos diodos de *by-pass* da série FV. Portanto, trata-se de uma situação que reduz a potência gerada e o fator de forma da curva I-V.

A correlação entre algumas assinaturas dificulta a identificação dos fatores de degradação com base apenas na análise das curvas I-V. Nessas situações, outros métodos de diagnóstico como a termografia e a eletroluminescência podem ser empregados. Por isso, a metodologia proposta neste trabalho permite detectar as situações de baixo desempenho e quantificar as perdas, mas limita-se a identificar os fatores de degradação mais corriqueiros e que podem ser percebidos pela análise da curva I-V, como a sujidade e o sombreamento.

Destaca-se que tanto o sombreamento como a sujidade podem ser facilmente identificados a olho nu. Porém, a metodologia proposta realiza essa operação de forma automática, o que viabiliza o diagnóstico da geração sem a presença de uma equipe de O&M no local para realizar a identificação dos fatores de degradação. Logo, uma equipe de O&M consegue acompanhar, de forma online, os relatórios que informam sobre o desempenho de cada uma das séries fotovoltaicas que compõem a usina. Assim sendo, a metodologia possibilita que as equipes de O&M sejam alocadas de forma otimizada para solucionar problemas na usina e não mais para identificar os problemas.

A metodologia proposta para diagnóstico da geração de usinas fotovoltaicas, mostrada na Figura 45, pode ser dividida em duas etapas: a detecção e a classificação. A etapa de detecção é responsável por verificar se o ponto de máxima potência da curva I-V da série FV condiz com o esperado. Caso contrário, ocorre a quantificação das perdas e a curva I-V é enviada para a próxima etapa do processo de diagnóstico. Na etapa de classificação ocorre a identificação dos fatores de degradação e a classificação da condição operacional da série fotovoltaica.

Vale mencionar que antes de processar qualquer informação, todas as curvas I-V registradas passam por um pré-processamento. Sendo essa etapa responsável por verificar a qualidade dos registros e pelo seu condicionamento. O pré-processamento impede que dados errôneos causem alarmes falsos na planta.

A etapa de detecção calcula um modelo fotovoltaico para cada uma das séries FV. Em um primeiro momento, os parâmetros dos modelos são estimados através de um processo que utiliza as curvas I-V das próprias séries FV. No entanto, o envelhecimento natural dos módulos fotovoltaicos implica na necessidade de recalculá-los de tempos em tempos. Assim, o método recalcula os parâmetros do modelo a cada processo de limpeza da série fotovoltaica. Sendo que a análise da evolução histórica desses modelos, que ficam armazenados na memória, permite quantificar o envelhecimento da usina.

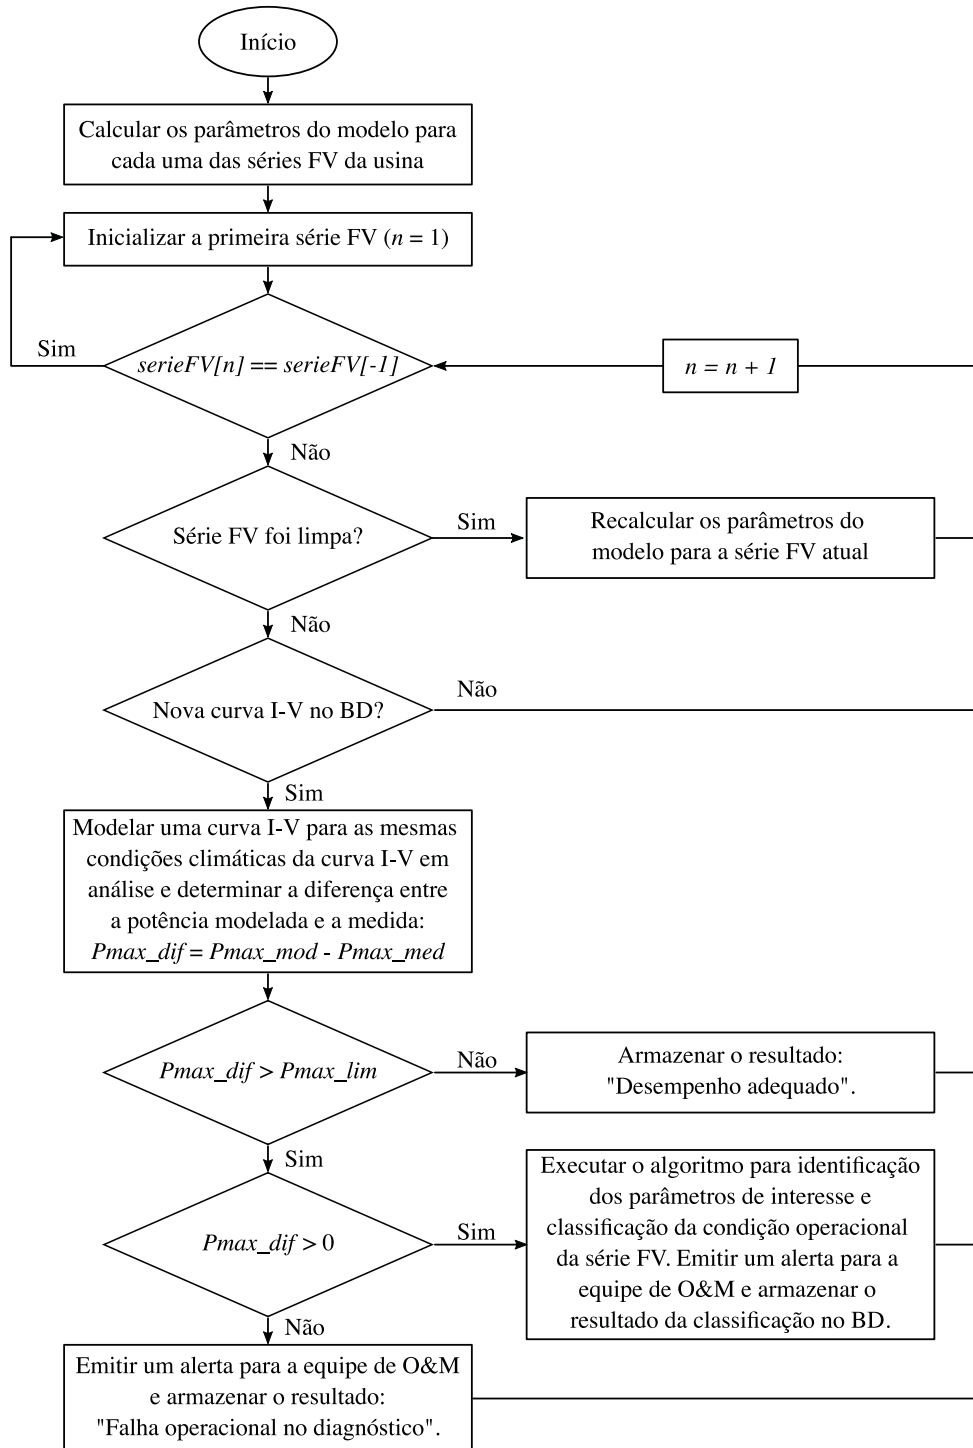
O método para diagnóstico da geração é executado ciclicamente e abrange individualmente todas as séries fotovoltaicas ($serieFV[n]$) do arranjo. Assim, inicia-se com a primeira série ($serieFV[1]$) e segue até a última série ($serieFV[-1]$) do arranjo, quando o processo é reiniciado. O método proposto, além de identificar o baixo desempenho, localiza a série fotovoltaica com a geração degradada para que as equipes de O&M possam atuar de forma assertiva e com celeridade na resolução dos problemas.

O banco de dados (BD) onde são armazenadas as curvas I-V é analisado e cada vez que uma nova curva é registrada ocorre a comparação entre a potência máxima extraída da curva I-V medida (P_{max_med}) com a potência máxima estimada pelo modelo (P_{max_mod}). Essa comparação permite avaliar se o desempenho da usina está adequado ou abaixo do esperado. As perdas da geração podem ser quantificadas, de forma aproximada, através da diferença entre a potência medida e a potência modelada ($P_{max_dif} = P_{max_med} - P_{max_mod}$).

A etapa de classificação é executada apenas se o desempenho da série fotovoltaica estiver abaixo do esperado. No entanto, a comparação direta entre a potência medida e a potência modelada pode causar alarmes falsos devido a fatores como o erro intrínseco presente nos modelos fotovoltaicos, as incertezas e os ruídos de medição. Portanto, recomenda-se que seja definido um valor limiar para a potência (P_{max_lim}), assim, quando a diferença entre a potência medida e a modelada (P_{max_dif}) não exceder ao limiar, considera-se que o desempenho da usina está adequado.

Ao definir o valor limiar, além de resolver o problema dos alarmes falsos, evita-se que o algoritmo de monitoramento gere, por exemplo, alarmes por um nível mínimo de sujidade. Logo, cabe a equipe de O&M dimensionar esse valor que corresponde ao grau de baixo desempenho

Figura 45 – Fluxograma da metodologia para diagnóstico da geração de usinas FV.



Fonte: Elaborada pelo autor (2023).

aceitável para cada série fotovoltaica. Essa escolha deve basear-se no custo de manutenção que é variável em cada usina.

Se o valor de P_{max_dif} exceder a potência limiar, então o desempenho da série fotovoltaica está degradado ou existe uma falha operacional no diagnóstico da geração. No método proposto é possível assumir que a potência máxima estimada pelo modelo fotovoltaico é sempre superior a potência máxima medida, pois o arranjo fotovoltaico está sujeito a fatores que degradam o seu desempenho com o passar do tempo. Assim, caso o valor de P_{max_dif} seja negativo, ou seja, a potência estimada seja inferior a potência medida, então existe uma falha operacional no diagnóstico da geração. Essa falha pode ser causada por um erro do próprio modelo ou por uma falha de medição das condições climáticas. Nesse caso, um alerta é emitido para a equipe de O&M sinalizando a falha.

Se o valor de P_{max_dif} exceder a potência limiar e for positivo, então uma rede neural artificial é utilizada para identificar os fatores de degradação e realizar a classificação da condição operacional da série fotovoltaica. A RNA projetada possui a topologia 4-9-3, sendo a camada de entrada composta pela razão entre pontos de interesse da curva I-V medida e os respectivos pontos que são extraídos pela curva I-V modelada. A camada de saída da rede é composta por neurônios que identificam as seguintes situações: sujidade, sombreamento e condução dos diodos de *by-pass*.

A metodologia proposta pode ser aplicada em séries fotovoltaicas individuais ou em conjuntos de séries. Afinal, o método realiza o diagnóstico da geração com base nas curvas I-V que são armazenadas em um banco de dados. Por exemplo, em usinas que possuem séries conectadas em paralelo, antes da conexão com o traçador de curvas I-V, o diagnóstico da geração é realizado com base nas curvas I-V deste conjunto de séries. No entanto, é evidente que nessas situações não será possível identificar a série fotovoltaica que está com o desempenho degradado, mas apenas o conjunto no qual essa série pertence.

Por fim, vale destacar que a metodologia realiza o diagnóstico da geração conforme as curvas I-V vão sendo armazenadas no banco dados. Assim sendo, a frequência do diagnóstico está diretamente relacionada com a configuração e a capacidade do traçador de curvas I-V.

A seguir, esse capítulo detalha cada uma das etapas que compõem a metodologia proposta para avaliação de desempenho de usinas fotovoltaicas. O pré-processamento dos dados é apresentado na Seção 4.1, a etapa de detecção na Seção 4.2 e a etapa de classificação na Seção 4.3.

4.1 PRÉ-PROCESSAMENTO DE DADOS

As curvas I-V das séries fotovoltaicas devem ser pré-processadas antes de serem utilizadas na avaliação de desempenho. O pré-processamento refere-se a execução de uma série de operações para transformar e preparar os dados. Em outras palavras, serve para converter os dados brutos em dados limpos. Avaliar a qualidade das informações antes de processá-las é

imprescindível, pois um registro incorreto pode implicar em falhas no processo, atrasos, tomadas de decisões improcedentes e, provavelmente, prejuízos. Em sistemas de monitoramento fotovoltaico, por exemplo, o ato de processar um dado errôneo pode motivar o deslocamento de uma equipe de O&M, por muitos quilômetros, para resolver uma falha inexistente.

A etapa de pré-processamento pode ser dividida em três fases: a extração, a transformação e o carregamento. A seguir, os principais pontos que envolvem cada uma dessas fases são discutidos:

Extração: a primeira fase do pré-processamento consiste em extrair os dados das fontes e compilá-los. No caso da metodologia proposta, essa fase é responsável por monitorar o banco de dados do traçador de curvas I-V e identificar quando houver o registro de uma nova curva. Quando identificada, a curva é extraída e encaminhada para a fase de transformação.

Transformação: nesta fase os dados devem ser convertidos, formatados e limpos para que possam ser armazenados na última etapa. No caso da metodologia proposta, esta fase consiste nas seguintes tarefas: busca por *outliers*, estimação da corrente de curto-circuito e ajuste da tensão da curva I-V.

A busca por *outliers* é essencial em qualquer análise de dados. Os *outliers* podem ser definidos como os dados que se diferenciam drasticamente de todos os outros, ou seja, são dados que fogem da normalidade. Esses registros precisam ser analisados e tratados com muito cuidado, pois podem implicar em um efeito borboleta, isto é, um pequeno erro inicial pode se propagar e criar um problema grave. A presença de *outliers* pode, por exemplo, causar a ocorrência de alarmes falsos na avaliação de desempenho de usinas. No caso das curvas I-V, os *outliers* podem ocorrer devido à falhas no circuito de conversão A/D. A identificação dos *outliers* pode ser realizada por algoritmos baseados em métodos estatísticos, como o *z-score*. Sendo essa a ferramenta que foi utilizada na metodologia proposta para diagnóstico da geração fotovoltaica.

O *z-score* é uma métrica que descreve a relação entre um valor e a média de um grupo de valores, em outras palavras, serve para contrastar os resultados de um teste com uma população "comum". O *z-score* é o número de desvios padrão que um ponto se encontra da média, sendo que na maioria dos grandes conjuntos de dados, 99% dos valores possuem o *z-score* entre -3 e 3, o que significa que estão dentro de 3 desvios padrão acima e abaixo da média (RETORNO, 2022). No caso das curvas I-V observou-se que os pontos geralmente possuem o *z-score* entre -4 e 4. Destaca-se que, ao identificar a presença de *outliers* é necessário tratá-los, o que geralmente se dá pela exclusão da amostra, ou pelo uso de métodos estatísticos que permitam encontrar uma aproximação para corrigir o dado discrepante. Neste trabalho optou-se pela exclusão da amostra.

A estimação da corrente de curto-circuito está relacionada com o fato de que I_{sc} é um ponto essencial na avaliação de desempenho de dispositivos fotovoltaicos. No entanto, a maioria dos traçadores de curvas I-V não tem a capacidade de medi-la. Afinal, esse ponto só pode ser mensurado se o banco de capacitores do traçador puder ser carregado com uma tensão negativa. Caso contrário, uma segunda alternativa está no uso de um método matemático para estimar I_{sc} . Ao observar uma curva I-V, percebe-se que a parte inicial da curva é aproximadamente linear, o que possibilita que o valor de I_{sc} seja aproximado por um método de extrapolação linear. Neste trabalho optou-se pela extrapolação de I_{sc} , conforme descrito na Seção 3.2.

Por fim, a última tarefa da fase de transformação compreende o ajuste da tensão da curva I-V. Os valores de tensão que são registrados ao adquirir a curva I-V de uma série fotovoltaica se dá pela soma da tensão de cada um dos módulos que compõem a série. Assim sendo, recomenda-se que os pontos de tensão da curva sejam divididos pela quantidade de módulos conectados na série. Esse procedimento permite obter uma curva I-V ajustada para os limites de um único módulo fotovoltaico, porém representando o comportamento médio da série FV. Logo, se a série estiver operando adequadamente, a curva I-V será próxima a de um módulo sadio. Se a série estiver com baixo desempenho, a curva I-V média irá divergir da curva do módulo sadio. Portanto, todas as curvas I-V apresentadas neste trabalho foram submetidas ao procedimento de ajuste da tensão.

Carregamento: consiste em carregar os dados que foram extraídos e transformados para um destino. No caso da metodologia proposta, o algoritmo para avaliação de desempenho foi projetado para importar as curvas I-V no formato '.csv'. Assim, recomenda-se que o arquivo csv de cada curva seja exportado conforme a estrutura apresentada na Figura 46, a qual é composta por cinco colunas, sendo elas: um identificador, a temperatura de operação dos módulos fotovoltaicos, a irradiância no plano inclinado, a tensão e a corrente da curva I-V. Além disso, para fins de organização, sugere-se que os parâmetros elétricos e climáticos sejam armazenados em um mesmo arquivo.

Ao final do pré-processamento tem-se uma maior confiabilidade em relação a qualidade dos registros que serão empregado na avaliação de desempenho das usinas fotovoltaicas. Logo, o risco de se obter uma avaliação incorreta pelo uso de dados de baixa qualidade é reduzido significativamente.

Figura 46 – Proposta de estrutura para o arquivo csv de uma curva I-V.

id	tempModulo	irrad	tensao	corrente
1	49,19	672,78590721		
2			0,00000000	6,42735488
3			0,34404478	6,42141309
4			0,63762966	6,41071787
5			0,92204001	6,40430073
6			1,19727583	6,40002264
			•	
			•	
			•	
497			33,61088134	0,02352950
498			33,61088134	0,02352950
499			33,61088134	0,02352950
500			33,61088134	0,02352950
501			33,64757945	0,00000000

Fonte: Elaborada pelo autor (2022).

4.2 DIAGNÓSTICO DE USINAS FOTOVOLTAICAS: ETAPA DE DETECÇÃO

A primeira etapa da metodologia proposta para avaliação de desempenhos de usinas fotovoltaicas é responsável por detectar se o desempenho de cada uma das séries FV está adequado. Essa tarefa pode ser realizada de diferentes formas, uma delas se dá pela comparação entre uma curva I-V de referência e as curvas medidas em campo. Contudo, para isso tornar-se possível, as curvas devem ser padronizadas em relação a condição climática presente durante os ensaios. A padronização viabiliza que curvas obtidas em condições climáticas distintas possam ser comparadas.

Os procedimentos atuais de conversão, como aqueles que estão regulamentados na Norma IEC 60891, são difíceis de serem aplicados em campo. Esses procedimentos exigem o cálculo de parâmetros de conversão, os quais só podem ser obtidos através de conjuntos de curvas adquiridas sob mesmo nível de irradiância e temperatura. Além disso, esses métodos foram projetados para a correção de curvas adquiridas em módulos fotovoltaicos saudáveis. Portanto, não podem ser aplicados na correção de curvas atípicas como, por exemplo, as curvas de séries FV parcialmente sombreadas.

Uma alternativa ao processo de conversão das curvas I-V está no uso de modelos fotovoltaicos, pois os modelos permitem estimar curvas para qualquer condição climática. Assim sendo, ao mensurar uma curva I-V em campo numa condição climática diferente do STC, ao invés de convertê-la, realiza-se uma comparação com a curva estimada por um modelo ensaiado nas mesmas condições climáticas da série em campo. As curvas I-V geradas por modelos representam o comportamento esperado dos módulos. Logo, se uma série fotovoltaica está com o desempenho abaixo do esperado, a comparação da curva mensurada com a curva modelada possibilita que

essa situação seja identificada.

Contudo, assim como ocorre no processo de conversão das curvas I-V, o uso de modelos também possui algum grau de complexidade. Por exemplo, ao utilizar os modelos baseados em redes neurais artificiais exige-se um extenso conjunto de curvas I-V em diferentes condições climáticas para o treinamento da RNA. Por outro lado, os modelos baseados em circuitos elétricos possuem uma série de parâmetros que precisam ser estimados previamente ao uso do modelo no método proposto. A maioria das técnicas de estimação de parâmetros para o modelo baseado em circuitos elétricos só é capaz de identificar esses parâmetros para um valor específico de irradiância e temperatura. Logo, sempre que uma nova curva I-V for modelada, deve-se, em um primeiro momento, estimar os novos parâmetros para que posteriormente seja realizado o cálculo da curva modelada. Isso exigiria que um conjunto extenso de parâmetros para o modelo elétrico fosse armazenado em memória para diversas condições ambientais ensaiadas. Ainda existiria o risco no momento de executar o modelo que a condição ambiental não estivesse na memória de treinamento, necessitando o usuário realizar um processo de interpolação não-trivial.

Apesar das dificuldades supracitadas, tanto o processo de conversão das curvas I-V como o uso de modelos fotovoltaicos são estratégias viáveis para padronizar a influência das condições climáticas na análise de curvas I-V. No entanto, alguns dos problemas que foram citados em relação aos modelos baseados em circuitos elétricos são solucionadas através do uso do Modelo Global Não-Linear (MGNL), o qual foi proposto por Silva (2019). A seguir, a modelagem de séries fotovoltaicas através do MGNL é detalhada.

4.2.1 O Modelo Global Não-Linear

O Modelo Global Não-Linear é baseado no circuito elétrico clássico de diodo único com cinco parâmetros para módulos fotovoltaicos, mas a proposta de Silva (2019) apresenta 15 parâmetros. Os parâmetros elétricos do circuito podem variar com as condições de irradiância e temperatura, ou seja, cada um dos 5 parâmetros originais possui a sua própria equação de dependência com as condições climáticas e com seus próprios parâmetros internos. Ao juntar os parâmetros internos das equações de cada um dos 5 parâmetros originais do circuito elétrico, se alcançam os 15 parâmetros mencionados.

Silva (2019) não só propôs o MGNL como também apresentou uma técnica para extrair os 15 parâmetros. Essa técnica permite estimar os parâmetros com significado físico, ao contrário da maioria dos modelos que realizam apenas uma aproximação de curvas I-V, podendo obter, por exemplo, uma resistência elétrica de valor negativo. Essa característica torna o MGNL capaz de emular o comportamento físico de módulos fotovoltaicos de diferentes tecnologias para diferentes condições ambientais, mantendo o vínculo com os fenômenos físicos que ocorrem internamente nos módulos fotovoltaicos.

Além disso, é importante destacar que os modelos fotovoltaicos, geralmente, estimam os parâmetros para uma condição específica de irradiância e temperatura. Logo, para obter uma curva I-V em uma outra condição climática, os parâmetros precisam ser recalculados. Contudo,

o MGNL modela os fenômenos físicos que ocorrem nas células fotovoltaicas em virtude das variações nas condições climáticas. Essa característica permite que o processo de estimação dos 15 parâmetros seja executado apenas uma vez, pois o MGNL torna-se válido para uma ampla faixa de irradiância e temperatura.

As equações propostas por Silva (2019) e que descrevem o Modelo Global Não-Linear são dadas por:

$$R_s = R_{s_{ref2}} \cdot \left[1 + \kappa_{R_s} \cdot (T - T_{ref}) \right] + R_{s_{ref1}} \cdot \left(\frac{G}{G_{ref}} \right)^{\gamma_{R_s}} \quad (23)$$

$$R_p = R_{p_{ref}} \cdot \left[1 + \kappa_{R_p} \cdot (T - T_{ref}) \right] \cdot \left(\frac{G}{G_{ref}} \right)^{\gamma_{R_p}} \quad (24)$$

$$A = A_{ref} \quad (25)$$

$$I_{sc} = \left[I_{sc_{ref}} + \alpha_i \cdot (T - T_{ref}) \right] \cdot \left(\frac{G}{G_{ref}} \right) \quad (26)$$

$$V_{oc} = V_{oc_{ref}} + \beta_T \cdot (T - T_{ref}) + \beta_S \cdot V_T \cdot \ln \left(\frac{G}{G_{ref}} \right) \quad (27)$$

$$I_g = I_{sc} \cdot \left(1 + \frac{R_s}{R_p} \right) \quad (28)$$

$$I_{sat} = \frac{I_g - V_{oc}/R_p}{e^{V_{oc}/V_T} - 1} \quad (29)$$

onde o subscrito *ref* identifica os parâmetros de referência. $R_{s_{ref1}}$ é a resistência série referente à irradiância. $R_{s_{ref2}}$ é a resistência série referente à temperatura. κ_{R_s} é o coeficiente linear de temperatura para resistência série. κ_{R_p} é o coeficiente linear de temperatura para resistência paralela. γ_{R_s} é o coeficiente exponencial da irradiância para resistência série. γ_{R_p} é o coeficiente exponencial da irradiância para resistência paralela. α_i é o coeficiente de variação da corrente de curto-circuito com a temperatura. β_S é o coeficiente de variação da tensão de circuito aberto com a irradiância. β_T é o coeficiente de variação da tensão de circuito aberto com a temperatura.

O MGNL é descrito por quinze parâmetros, mas apenas onze são estimados pelo algoritmo, sendo eles: $R_{s_{ref1}}$, $R_{s_{ref2}}$, $R_{p_{ref}}$, κ_{R_s} , κ_{R_p} , γ_{R_s} , γ_{R_p} , A_{ref} , α_i , β_S e β_T . Todos esses parâmetros

correspondem às características físicas intrínsecas dos módulos fotovoltaicos. Já os parâmetros $I_{sc_{ref}}$ e $V_{oc_{ref}}$ são definidos no momento em que é escolhida uma curva I-V de referência. Por fim, os parâmetros I_g e I_{sat} são calculados como consequência dos outros parâmetros mencionados, usando as equações (28) e (29), e correspondem à condição operacional do módulo fotovoltaico, ou seja, esses parâmetros variam conforme as condições climáticas (SILVA, 2019).

O processo para estimação dos parâmetros do MGNL ocorre conforme o fluxograma da Figura 47. Em um primeiro momento, os seguintes parâmetros de entrada são definidos: constante de Boltzmann (k), carga do elétron (q), quantidade de células fotovoltaicas conectadas em série em um módulo (N_s), coeficiente de temperatura para corrente de curto-circuito ($\alpha_{I_{sc}}$) e coeficiente de temperatura para tensão de circuito aberto ($\beta_{V_{oc}}$).

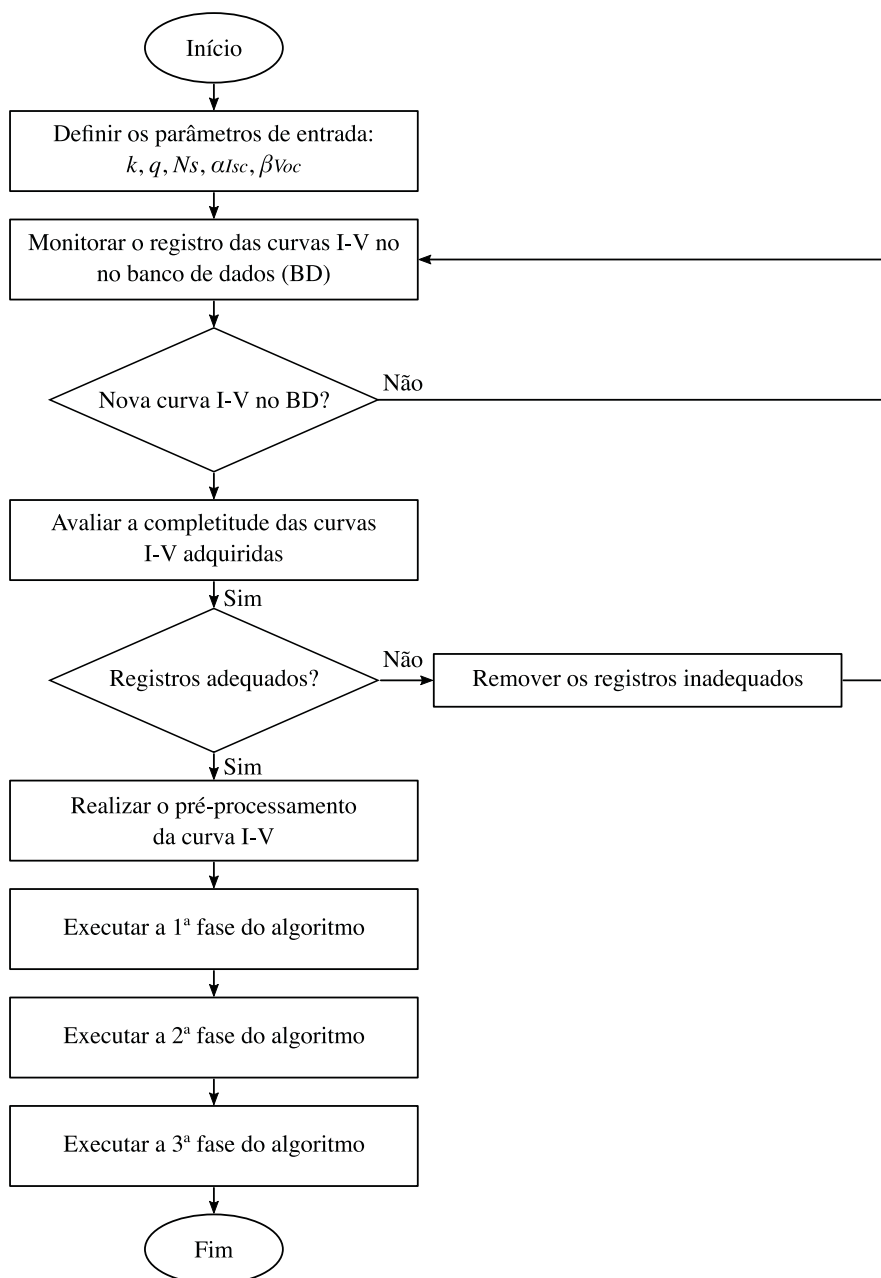
Após a definição dos parâmetros de entrada, um conjunto de curvas I-V deve ser adquirido. De acordo com Silva (2019), são necessárias pelo menos seis curvas, sendo que elas devem englobar um intervalo relevante de irradiância (ΔG) e temperatura (ΔT), já que, após o processo de estimação, o MGNL estará apto a reproduzir o comportamento físico dos módulos fotovoltaicos modelados no mesmo intervalo de ΔG e ΔT . Por exemplo, se o objetivo for avaliar o desempenho de séries fotovoltaicas na faixa de 700 W/m^2 até 1000 W/m^2 . Então, o conjunto de curvas I-V deve englobar pelo menos uma curva abaixo de 700 W/m^2 e outra acima de 1000 W/m^2 .

Durante o período de aquisição das curvas I-V, sempre que uma nova curva for mensurada e registrada no banco de dados ocorre a avaliação da completude. Esse processo consiste em verificar se, até o momento, foram adquiridas ao menos seis curvas I-V e elas satisfazem as especificações que foram definidas de forma heurística pelo operador do sistema. Por exemplo:

1. Uma curva com irradiância abaixo de 700 W/m^2 ;
2. Uma curva com irradiância entre 730 W/m^2 e 830 W/m^2 ;
3. Uma curva com irradiância entre 860 W/m^2 e 960 W/m^2 ;
4. Uma curva com irradiância acima de 1000 W/m^2 ;
5. Uma curva com temperatura abaixo de $40 \text{ }^\circ\text{C}$;
6. Uma curva com temperatura acima de $60 \text{ }^\circ\text{C}$.

Após a aquisição do conjunto de curvas I-V, os parâmetros do MGNL são estimados através de um algoritmo de otimização. Os valores iniciais e os limites superior e inferior dos parâmetros a serem estimados são mostrados na Tabela 12. O cálculo e a justificativa para o uso desses valores estão contidos no trabalho de Silva (2019).

Figura 47 – Fluxograma do processo para estimação dos parâmetros do MGNL.



Fonte: Elaborada pelo autor (2022).

Tabela 12 – Limites e ponto inicial dos parâmetros a serem estimados pelo MGNL.

Parâmetro	Limite inferior (L.I.)	Limite superior (L.S.)	Valor inicial
R_{sref1}	0	R_{sref}	$(L.I. + L.S.)/2$
R_{sref2}	0	R_{sref}	$(L.I. + L.S.)/2$
R_{pref}	R_{pref_min}	1000	$(L.I. + L.S.)/2$
A_{ref}	0	3	$(L.I. + L.S.)/2$
α_i	10^{-4}	10^{-2}	$\alpha_{I_{sc}}$
β_T	-1	-10^{-3}	$\beta_{V_{oc}}$
β_S	0	2	1
γ_{R_s}	$\gamma_{R_s_min}$	0	$(L.I. + L.S.)/2$
γ_{R_p}	$\gamma_{R_p_min}$	0	$(L.I. + L.S.)/2$
κ_{R_s}	$-\kappa_{R_s_max}$	$\kappa_{R_s_max}$	$(L.I. + L.S.)/2$
κ_{R_p}	$-\kappa_{R_p_max}$	0	$(L.I. + L.S.)/2$
I_{scref}	Determinados a partir da curva I-V de referência		
V_{ocref}			
I_g	Determinados a partir dos demais parâmetros, pelas equações (28) e (29)		
I_{sat}			

Fonte: Adaptado de Silva (2019).

O processo de estimação dos parâmetros do MGNL através de um algoritmo de otimização, conforme proposto por Silva (2019), pode ser dividido em três fases, são elas:

Primeira fase uma curva I-V deve ser escolhida como referência, recomenda-se que ela represente as condições médias de irradiância e temperatura do conjunto de treinamento. Nessa fase são obtidos os seguintes parâmetros de referência: I_{scref} , V_{ocref} , R_{pref} , R_{sref} e A_{ref} .

Segunda fase são obtidos os parâmetros que tornam o modelo capaz de extrapolar os valores de I_{sc} e V_{oc} para quaisquer condições ambientais. São estimados: α_i , β_S e β_T .

Terceira fase emprega-se o conjunto de treinamento com o objetivo de obter os demais parâmetros que compõem o MGNL: R_{sref1} , R_{sref2} , κ_{R_s} , κ_{R_p} , γ_{R_s} e γ_{R_p} . Nessa fase, ocorre a busca simultânea de seis parâmetros, o que implica em alto custo computacional e pode restringir a escolha do algoritmo de otimização a ser utilizado.

Em sua versão original, Silva (2019) propôs que os parâmetros fossem estimados através do algoritmo de otimização “busca por padrões” (*pattern search*, PS). O PS foi escolhido devido à sua capacidade em obter excelentes resultados de otimização para problemas complexos com

múltiplos pontos de mínimo local descontínuos, como é o caso do MGNL. O algoritmo para estimação dos parâmetros foi implementado pelo autor no ambiente Matlab.

Neste trabalho, optou-se por converter o algoritmo para a linguagem Python, o que justifica-se pela necessidade de estimar os parâmetros do MGNL em dispositivos com menor capacidade de processamento, como as placas Raspberry Pi. Contudo, até o momento, a linguagem Python não possui uma biblioteca que implemente o PS com a mesma capacidade do Matlab. Assim sendo, outros algoritmos de otimização foram investigados, como: Nelder-Mead, L-BFGS-B, TNC, SLSQP, Powell, e trust-constr.

Os melhores resultados obtidos em ambiente Python foram alcançados com o uso combinado do método de Powell na primeira fase do MGNL e o método da Programação Quadrática Sequencial (SLSQP) nas demais fases. O desempenho do MGNL ao ser ensaiado nos ambientes Matlab e Python pode ser comparado através da Tabela 13. Deve-se destacar que as curvas I-V empregadas nessa análise não foram utilizadas no processo de treinamento do MGNL.


Tabela 13 – Pontos de interesse de curvas I-V modeladas pelo MGNL em ambientes distintos.

1ª Curva I-V - Irradiância: 728 W/m² e Temperatura: 46,23 °C					
Método	Isc (A)	Voc (V)	Imp (A)	Vmp (V)	Pmp (W)
Valor real	7,067	34,26	6,419	27,73	178,0
Busca por padrões (Matlab)	6,926	34,16	6,239	27,73	173,0
Powell + SLSQP (Python)	6,929	34,13	6,333	27,45	173,8
2ª Curva I-V - Irradiância: 843 W/m² e Temperatura: 53,14 °C					
Método	Isc (A)	Voc (V)	Imp (A)	Vmp (V)	Pmp (W)
Valor real	8,118	33,81	7,444	26,72	198,9
Busca por padrões (Matlab)	8,048	33,80	7,233	27,00	195,3
Powell + SLSQP (Python)	8,045	33,81	7,166	27,20	194,9
3ª Curva I-V - Irradiância: 913 W/m² e Temperatura: 46,94 °C					
Método	Isc (A)	Voc (V)	Imp (A)	Vmp (V)	Pmp (W)
Valor real	8,654	34,17	7,891	27,22	214,8
Busca por padrões (Matlab)	8,691	34,55	7,839	27,51	215,6
Powell + SLSQP (Python)	8,694	34,55	7,656	28,00	214,4
4ª Curva I-V - Irradiância: 991 W/m² e Temperatura: 48,61 °C					
Método	Isc (A)	Voc (V)	Imp (A)	Vmp (V)	Pmp (W)
Valor real	9,398	34,27	8,592	27,07	232,6
Busca por padrões (Matlab)	9,442	34,54	8,465	27,40	231,9
Powell + SLSQP (Python)	9,443	34,58	8,129	28,00	227,6

Fonte: Elaborada pelo autor (2022).


A capacidade do MGNL para modelar curvas I-V, sob níveis distintos de irradiância, em ambiente Python pode ser vista na Figura 48. Neste caso, mostra-se uma comparação entre as curvas modeladas e as curvas mensuradas em campo.

Figura 48 – Comparação entre curvas I-V mensuradas e modeladas pelo MGNL em Python.



(a) Irradiância: 728 W/m². Temperatura 46,23 °C.

(b) Irradiância: 843 W/m². Temperatura 53,14 °C.



(c) Irradiância: 913 W/m². Temperatura 46,94 °C.


(d) Irradiância: 991 W/m². Temperatura 48,61 °C.

Fonte: Elaborada pelo autor (2022).


Nota-se que o modelo apresenta dificuldades em reproduzir a região do joelho da curva I-V sob alta irradiância. A comparação com o algoritmo PS mostra que a conversão para Python reduziu a precisão do modelo. No entanto, foram agregadas as vantagens de utilizar uma linguagem multiplataforma e livre (até para projetos comerciais). Além disso, a diferença entre as curvas não mostrou-se significativa para diagnóstico da geração das séries fotovoltaicas.

Uma outra análise da capacidade do MGNL em ambiente Python pode ser vista na Figura 49. Neste caso, é possível avaliar a capacidade do modelo em reproduzir os cinco pontos de interesse de uma curva I-V. O ensaio consistiu em modelar 20 curvas I-V e comparar os pontos de interesse das curvas modeladas com as curvas mensuradas. A faixa de irradiância das curvas foi de 709 W/m² até 996 W/m² e a faixa de temperatura foi de 41,47 °C até 56,69 °C.


Figura 49 – Relação entre os pontos de interesse medidos e modelados pelo MGNL.




(a) Corrente de curto-circuito.




(b) Tensão de circuito aberto.



(c) Corrente no ponto de máxima potência.



(d) Tensão no ponto de máxima potência.



(e) Potência máxima.

Fonte: Elaborada pelo autor (2022).

A relação entre os pontos de interesse mostra a alta capacidade do modelo em reproduzir os valores de corrente, em especial, a corrente de curto-circuito. Por outro lado, percebe-se uma maior fragilidade na reprodução dos valores de tensão, em especial, na tensão do ponto de máxima potência.

4.3 DIAGNÓSTICO DE USINAS FOTOVOLTAICAS: ETAPA DE CLASSIFICAÇÃO

A etapa de classificação da metodologia proposta para diagnóstico da geração fotovoltaica de usinas é responsável por identificar os fatores de degradação e classificar a condição operacional das séries FV. A execução desta etapa está condicionada ao baixo desempenho da série. Em outras palavras, a etapa de classificação só é realizada se a diferença entre a potência medida na série e a potência estimada pelo MGNL for superior ao valor da potência limiar.

Conforme foi descrito anteriormente, a etapa de classificação permite identificar e classificar de forma automática algumas situações corriqueiras que provocam a degradação de desempenho em séries fotovoltaicas, como a sujidade e o sombreamento. Falhas relacionadas como a fissura de células, a presenças de trilhas de caracol e a delaminação, por exemplo, podem ser detectadas devido ao decréscimo da potência gerada, mas não serão corretamente classificadas. No entanto, essas situações podem ser diagnosticadas pela equipe de O&M através de ferramentas específicas como a termografia e a eletroluminescência.

Nesta etapa, a identificação dos fatores de degradação é realizada através de uma rede neural artificial. Justifica-se a escolha por uma RNA devido a sua capacidade de classificação e por se tratar de uma ferramenta que está se consolidando cada vez mais na indústria. De acordo com Karatepe, Hiyama et al. (2011), por se tratar de um problema de classificação, onde objetiva-se a alta precisão, a melhor estrutura para esse tipo de problema são as redes neurais artificiais *feedforward* de múltiplas camadas.

O projeto de uma RNA recai sobre o problema de estabelecer a quantidade de neurônios que devem compor a camada de entrada, as camadas ocultas e a camada de saída. Geralmente, esse processo inicia pela camada de saída, pois a quantidade de neurônios está relacionada com a necessidade de classificação. Assim sendo, foram definidas as seguintes condições operacionais para serem classificadas pela RNA:

- Série fotovoltaica limpa e sem sombreamento parcial.
- Série fotovoltaica limpa e sombreada parcialmente com ativação de diodos de *by-pass*.
- Série fotovoltaica limpa e sombreada parcialmente sem ativação de diodos de *by-pass*.
- Série fotovoltaica suja e sem sombreamento parcial.
- Série fotovoltaica suja e sombreada parcialmente com ativação de diodos de *by-pass*.
- Série fotovoltaica suja e sombreada parcialmente sem ativação de diodos de *by-pass*.

Logo, a rede deve ser projetada com três neurônios na camada de saída. O primeiro neurônio para indicar a sujidade, o segundo o sombreamento e o terceiro a condução dos diodos de *by-pass*. O impacto desses fatores na curva I-V de uma série fotovoltaica pode ser visto na Figura 50.

A condição operacional da série fotovoltaica pode ser identificada ao analisar os pontos de interesse da curva I-V junto da condição climática presente no instante do ensaio. Por exemplo, ao comparar as Figuras 50a e 50b que possuem uma condição climática semelhante, nota-se que a sujidade causa a redução de I_{sc} e I_{mp} . Assim como, ao analisar as Figuras 50a e 50c, constata-se que o sombreamento reduz V_{mp} . Já a ocorrência de pequenos sombreamentos, inferiores ao tamanho de uma célula fotovoltaica, difere de sombreamentos significativos devido ao formato do degrau que surge na curva I-V, conforme mostram as Figuras 50c e 50e. Logo, propõem-se que a camada de entrada da RNA seja composta pelas seguintes relações:

$$I_{scnorm} = \frac{I_{scmed}}{I_{scmod}} \quad (30)$$

$$V_{ocnorm} = \frac{V_{ocmed}}{V_{ocmod}} \quad (31)$$

$$I_{mpnorm} = \frac{I_{mpmed}}{I_{mpmod}} \quad (32)$$


$$V_{mpnorm} = \frac{V_{mpmed}}{V_{mpmod}} \quad (33)$$

onde o subscrito *med* identifica os parâmetros medidos em campo, *mod* os parâmetros modelados pelo MGNL e *norm* os parâmetros normalizados.


Para exemplificar, os parâmetros normalizados das curvas I-V da Figura 50 são apresentados na Tabela 14. Vale destacar que esses dados foram pré-processados, ou seja, a tensão da série fotovoltaica foi dividida pelo quantitativo de módulos presentes na série (24 módulos). Essa análise preliminar evidencia que os parâmetros normalizados são bons indicadores para o processo de classificação da RNA.

O projeto da topologia da RNA é concluído ao definir a quantidade de camadas ocultas e de neurônios que compõem cada uma dessas camadas. Esse processo não é trivial, pois deve-se preservar a capacidade de classificação da rede, sem aumentar desnecessariamente a sua complexidade. Haykin (2001) apresenta um roteiro para a busca da melhor arquitetura, modificando o número de camadas ocultas e o número de neurônios. No entanto, até o momento, não existe uma solução exata para este problema. Baptista et al. (2017) recomenda que para uma rede com n_i neurônios na camada de entrada, a camada oculta seja composta por $2 \cdot n_i + 1$ neurônios. Essa solução é baseada no equilíbrio entre a convergência e a generalização da RNA.


Figura 50 – Impacto da sujeira e do sombreamento na curva I-V de uma série fotovoltaica.



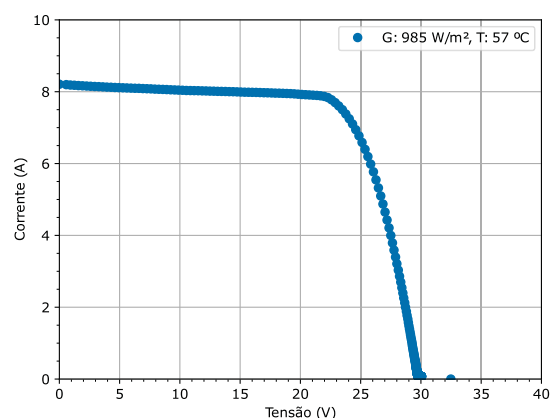
(a) Série FV limpa e sem sombreamento.




(b) Série FV suja e sem sombreamento.




(c) Série FV limpa e sombreada com ativação de diodos de *by-pass*.



(d) Série FV suja e sombreada com ativação de diodos de *by-pass*.



(e) Série FV limpa e sombreada sem ativação de diodos de *by-pass*.



(f) Série FV suja e sombreada sem ativação de diodos de *by-pass*.

Fonte: Elaborada pelo autor (2022).

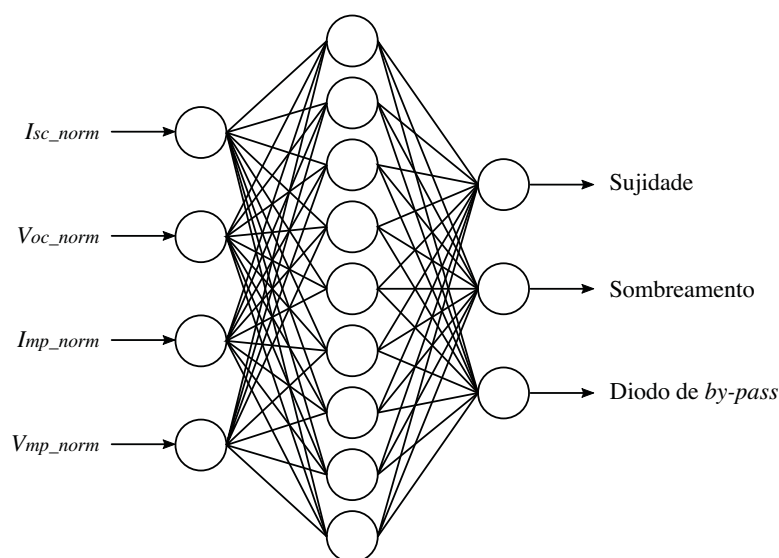
Tabela 14 – Relações I_{scnorm} , V_{ocnorm} , I_{mpnorm} e V_{mpnorm} para as curvas I-V da Figura 50.

Condição operacional da série FV	I_{scmed}	I_{scmod}	I_{scnorm}
Limpa e sem sombreamento	9,13	9,14	1,00
Suja e sem sombreamento	7,87	9,13	0,86
Limpa e sombreada com ativação de diodos de <i>by-pass</i>	8,76	8,76	1,00
Suja e sombreada com ativação de diodos de <i>by-pass</i>	8,21	9,43	0,87
Limpa e sombreada sem ativação de diodos de <i>by-pass</i>	9,23	9,26	1,00
Suja e sombreada sem ativação de diodos de <i>by-pass</i>	7,76	8,84	0,88
Condição operacional da série FV	V_{ocmed}	V_{ocmod}	V_{ocnorm}
Limpa e sem sombreamento	33,60	33,87	0,99
Suja e sem sombreamento	33,06	33,65	0,98
Limpa e sombreada com ativação de diodos de <i>by-pass</i>	32,90	33,52	0,98
Suja e sombreada com ativação de diodos de <i>by-pass</i>	32,48	33,80	0,96
Limpa e sombreada sem ativação de diodos de <i>by-pass</i>	34,46	34,65	0,99
Suja e sombreada sem ativação de diodos de <i>by-pass</i>	32,91	33,45	0,98
Condição operacional da série FV	I_{mpmed}	I_{mpmod}	I_{mpnorm}
Limpa e sem sombreamento	8,36	7,88	1,06
Suja e sem sombreamento	7,35	7,86	0,93
Limpa e sombreada com ativação de diodos de <i>by-pass</i>	7,92	7,62	1,04
Suja e sombreada com ativação de diodos de <i>by-pass</i>	7,60	8,04	0,95
Limpa e sombreada sem ativação de diodos de <i>by-pass</i>	7,77	8,02	0,97
Suja e sombreada sem ativação de diodos de <i>by-pass</i>	6,51	7,67	0,85
Condição operacional da série FV	V_{mpmed}	V_{mpmod}	V_{mpnorm}
Limpa e sem sombreamento	26,24	27,30	0,96
Suja e sem sombreamento	25,90	27,05	0,96
Limpa e sombreada com ativação de diodos de <i>by-pass</i>	23,54	26,90	0,87
Suja e sombreada com ativação de diodos de <i>by-pass</i>	23,18	27,20	0,85
Limpa e sombreada sem ativação de diodos de <i>by-pass</i>	28,65	28,10	1,02
Suja e sombreada sem ativação de diodos de <i>by-pass</i>	27,37	26,85	1,02

Fonte: Elaborada pelo autor (2022).

Assim sendo, neste trabalho foram realizados ensaios com uma RNA formada por uma e duas camadas ocultas e quantidades distintas de neurônios em cada camada. Foi identificado que a solução com o melhor equilíbrio entre convergência e generalização está no emprego de uma camada oculta com 9 neurônios. Portanto, a RNA utilizada na identificação dos fatores de degradação das séries fotovoltaicas dispõe da topologia 4-9-3, ou seja, quatro neurônios na camada de entrada, nove na camada oculta e três na camada de saída. A estrutura da RNA proposta é mostrada na Figura 51.

Figura 51 – Estrutura da RNA proposta para identificar os fatores de degradação de uma série fotovoltaica.

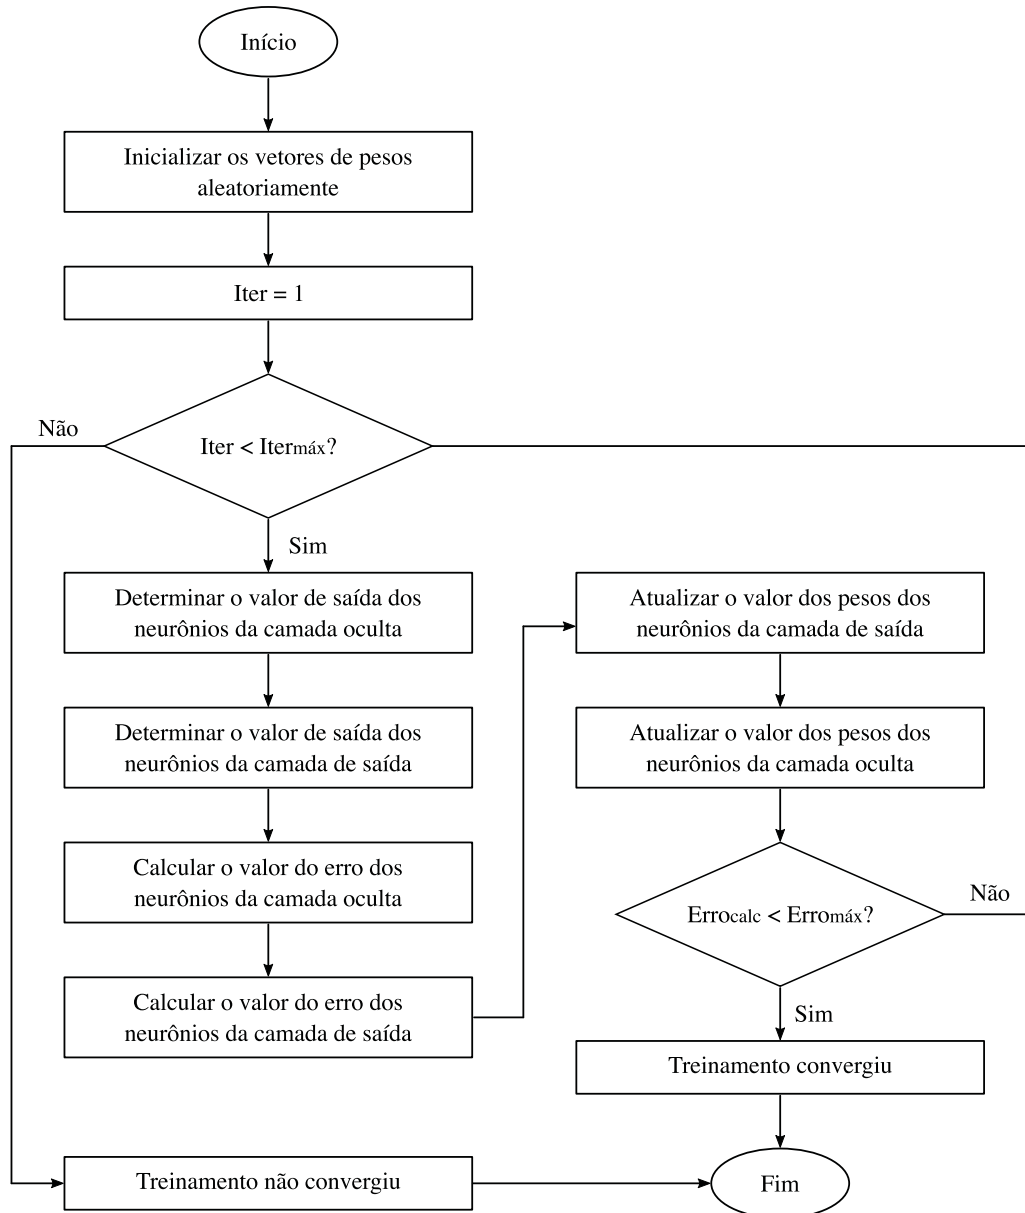


Fonte: Elaborada pelo autor (2022).

A RNA proposta é treinada através do algoritmo *backpropagation*. Sendo esse um algoritmo clássico e considerado a essência do treinamento de redes neurais. O algoritmo foi desenvolvido na década de 1960 e popularizado pelo trabalho de Rumelhart, Hinton e Williams (1986). O *backpropagation*, também denominado de algoritmo de retropropagação, realiza o ajuste dos pesos com base na taxa de erro obtida na iteração anterior, conforme mostra a Figura 52. O ajuste adequado dos pesos permite reduzir as taxas de erro e tornar a rede neural confiável.

No processo de treinamento, em um primeiro momento, os pesos são inicializados de forma aleatória, mas dentro do intervalo de -1 a 1. Após, inicia-se o processo iterativo e o valor dos neurônios da camada oculta e da camada de saída são determinados através da função de ativação. Em seguida, realiza-se o cálculo do erro ao comparar os valores estimados pela rede com o valores desejados, os quais estão contemplados no conjunto de treinamento. Por fim, retorna-se da camada de saída em direção a camada de entrada atualizando o valor dos pesos de modo que o erro seja minimizado.

Figura 52 – Fluxograma do algoritmo *backpropagation* aplicado no treinamento da RNA.



Fonte: Elaborada pelo autor (2023).

O cálculo da saída dos neurônios ocorre através da função de ativação, sendo essa função um elemento extremamente importante, pois ela decide se um neurônio deve ser ativado ou não. Em outras palavras, ela determina se a informação recebida pelo neurônio é relevante ou deve ser ignorada. A função de ativação é responsável pela transformação não-linear que ocorre com o sinal de entrada da rede.

No caso da RNA proposta, optou-se pelo uso da função de ativação sigmoide (ϕ), essa função se destaca pela sua capacidade em modelar comportamentos binários e possui uma saída entre 0 e 1. A função sigmoide pode ser calculada por:

$$\phi(x) = \frac{1}{1 + e^{-x}} \quad (34)$$

onde x é o valor de entrada da função de ativação.

O treinamento é realizado utilizando os valores decimais que são produzidos pela função de ativação, sem nenhum arredondamento. Contudo, após o treinamento, ou seja, durante a aplicação da rede no processo de identificação dos fatores de degradação é considerado que: se o primeiro neurônio da camada de saída apresentar um valor menor ou igual à 0,5 então a série FV está limpa, caso contrário a série está suja. A mesma analogia vale para o segundo neurônio que indica a condição de sombreamento da série e o terceiro neurônio que indica a ativação dos diodos de *by-pass*.

O processo de treinamento chega ao fim quando o erro calculado for inferior ao erro máximo tolerável, o que indica a convergência da rede. No entanto, o treinamento pode ser interrompido caso o número de iterações extrapole o limite estabelecido, essa situação indica que o treinamento não convergiu e a rede não está capacitada a identificar os fatores de degradação da série fotovoltaica.

Após o processo de treinamento, algumas vezes, a rede neural pode se especializar demasiadamente em relação aos padrões do conjunto de treinamento, gerando um problema de superaprendizado. Este problema pode ser evitado ao utilizar um conjunto para validação e outro para teste. O conjunto de validação é usado para definir um critério de parada caso o erro de validação comece a subir, mesmo que o de treinamento caia. Isso ocorre quando a RNA está se superespecializando e perdendo a capacidade de ser um categorizador generalista, ou seja, de extrapolar a categorização em cenários diferentes de treinamento. Enquanto, o conjunto de testes é usado apenas para testar a RNA treinada.

4.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou uma metodologia para diagnosticar a geração de usinas fotovoltaicas através da análise de curvas I-V. O método permite identificar as situações de baixo desempenho em cada uma das séries fotovoltaicas, quantificar as perdas da geração e classificar a condição operacional da série em relação à sujidade e sombreamento parcial com ou sem a ativação dos diodos de *by-pass*.

O capítulo destacou a importância de pré-processar os dados antes de aplicá-los no método para diagnóstico da geração. Essa etapa inicial consiste em uma série de operações para transformar e preparar os dados com o objetivo de evitar o processamento de dados errôneos, o que pode implicar na classificação incorreta da condição operacional de uma série FV. A etapa de pré-processamento é dividida em três fases, sendo elas: a extração, a transformação e o carregamento. Entre as operações realizadas vale mencionar a busca por *outliers*, a extrapolação da corrente de curto-circuito e o ajuste da tensão da curva I-V.

A metodologia para diagnóstico da geração foi dividida em duas etapas: a detecção e a classificação. A primeira etapa é responsável por identificar as situações de baixo desempenho e quantificar as perdas. A segunda etapa realiza a classificação da condição operacional de cada série fotovoltaica.

A etapa de detecção identifica as situações de baixo desempenho ao comparar o ponto de máxima potência da curva I-V medida em cada série FV com a potência máxima estimada por um modelo fotovoltaico que foi calculado para aquela mesma série. No caso, optou-se pelo Modelo Global Não-Linear que foi proposto por Silva (2019). Esse modelo possui 15 parâmetros e se destaca pela capacidade de emular o comportamento físico de módulos fotovoltaicos de diferentes tecnologias para diferentes condições ambientais. A estimação desses parâmetros, assim como todo o método para diagnóstico da geração foi projetado para ser executado em ambiente Python.

Vale destacar que os parâmetros do modelo são recalculados automaticamente a cada processo de limpeza da série fotovoltaica. Essa operação evita que o envelhecimento natural dos módulos atrapalhe no diagnóstico da geração. Além disso, a evolução histórica desses modelos permite quantificar o envelhecimento da usina.

Por fim, a etapa de classificação é responsável por determinar a condição operacional da série fotovoltaica, que pode ser: i) limpa e sem sombreamento parcial; ii) limpa e sombreada parcialmente com ativação de diodos de *by-pass*; iii) limpa e sombreada parcialmente sem ativação de diodos de *by-pass*; iv) suja e sem sombreamento parcial; v) suja e sombreada parcialmente com ativação de diodos de *by-pass*; vi) suja e sombreada parcialmente sem ativação de diodos de *by-pass*.

A classificação da condição operacional é realizada através de uma rede neural artificial com a topologia 4-9-3. Sendo a camada de entrada composta por um conjunto de parâmetros normalizados (I_{scnorm} , V_{ocnorm} , I_{mpnorm} e V_{mpnorm}) que são obtidos através da relação entre os parâmetros extraídos da curva I-V e os parâmetros estimados pelo modelo FV. Os três neurônios da camada de saída indicam a presença de sujeira, sombreamento e ativação dos diodos de *by-pass*. A RNA foi projetada com a função de ativação sigmoide e o treinamento é realizado com o algoritmo *backpropagation*.

5 RESULTADOS

O método proposto para monitoramento e avaliação de desempenho integrados à usinas fotovoltaicas foi calibrado, ajustado e ensaiado preliminarmente em laboratório, mas a sua validação foi realizada em campo. Uma usina fotovoltaica de 100 kW localizada na Universidade Federal de Santa Maria (UFSM) recebeu a instalação do traçador de curvas I-V e teve o seu desempenho avaliado conforme a metodologia proposta neste trabalho.

Este capítulo discorre sobre os resultados que foram obtidos a partir dos ensaios de validação. A estrutura da usina fotovoltaica é apresentada na Seção 5.1, a validação do traçador de curvas I-V na Seção 5.2 e a validação da metodologia para avaliação de desempenho de usinas na Seção 5.3.

5.1 APRESENTAÇÃO DA USINA FOTOVOLTAICA

A usina fotovoltaica onde foram realizados os ensaios de validação do traçador de curvas I-V e da metodologia para diagnóstico da geração está localizada em Santa Maria, Rio Grande do Sul. A usina entrou em operação no mês de outubro de 2018 e foi consequência de uma parceria entre o Instituto Nacional de Ciência e Tecnologia em Geração Distribuída de Energia Elétrica (INCT-GD), a CPFL Energia, o Instituto de Redes Inteligentes (INRI) e a UFSM. A usina possui latitude -29,712, longitude -53,719 e altitude média de 113 m. A irradiação solar global anual é de aproximadamente 1.722 kWh/m². O local da instalação da usina não possui problemas significativos quanto a presença de fumaça, poeiras e outras sujeiras.

A usina possui 384 módulos fotovoltaicos, ocupando uma área total de aproximadamente 2.000 m². Os módulos com tecnologia policristalina são produzidos pela Canadian Solar e possuem a potência nominal de 270 W, cujas especificações técnicas são apresentadas na Tabela 15. A matriz fotovoltaica está dividida em 16 séries, cada uma composta por 24 módulos, que são conectadas individualmente no inversor.

Os módulos são fixados em estruturas metálicas montadas no chão com inclinação de 30°. A estrutura está voltada para o norte e permite o fluxo de ar por baixo dos módulos em todas as direções. A Figura 53 mostra a disposição de uma parcela dos módulos fotovoltaicos instalados na usina.

Um inversor fotovoltaico central, modelo INGECON SUN 3Play 100TL, produzido pela Ingeteam é responsável pela conversão da energia gerada. O inversor opera com tensão máxima de 1.100 V em c.c. e corrente de curto-circuito de 203 A. Em relação ao monitoramento, o inversor destaca-se pela capacidade de medir a corrente elétrica individual de cada série.

A usina possui um eletrocentro construído em alvenaria e climatizado para acondicionar o inversor, o sistema de medição e serve de base para uma central meteorológica, conforme mostra a Figura 53. As séries fotovoltaicas, antes de serem conectadas ao inversor, passam por um painel elétrico, localizado no interior deste eletrocentro. No painel, cada série fotovoltaica é conectada a um circuito com DPS e duas chaves seccionadoras em série.

Tabela 15 – Especificações técnicas do módulo fotovoltaico CS6K-270P.

Parâmetro	Valor
Potência nominal máxima (P_{max})	270 W
Tensão no ponto de máxima potência (V_{mp})	30,8 V
Corrente no ponto de máxima potência (I_{mp})	8,75 A
Tensão de circuito aberto (V_{oc})	37,9 V
Corrente de curto-circuito (I_{sc})	9,32 A
Coefficiente de temperatura de P_{max} (γ_{mpp})	-0,41 %/°C
Coefficiente de temperatura de V_{oc} ($\beta_{V_{oc}}$)	-0,31 %/°C
Coefficiente de temperatura de I_{sc} ($\alpha_{I_{sc}}$)	0,053 %/°C
Total de células fotovoltaicas por módulo	60 (6x10)

Fonte: Elaborada pelo autor (2022).

Figura 53 – Usina fotovoltaica localizada na Universidade Federal de Santa Maria.



Fonte: Elaborada pelo autor (2022).

5.2 VALIDAÇÃO DO TRAÇADOR DE CURVAS I-V NA USINA


O traçador de curvas I-V proposto neste trabalho é composto pelos módulos comutadores, o módulo para aquisição das curvas I-V, o módulo para aquisição dos parâmetros climáticos e o módulo controlador. A estrutura do traçador de curvas foi instalada no eletrocentro da usina, conforme mostra a Figura 54.

Figura 54 – Traçador de curvas I-V integrado à usina fotovoltaica.



(a) Painel de conexão das séries FV.

(b) Módulo para aq. dos parâmetros climáticos.



(c) Detalhe de um módulo comutador instalado no interior do painel elétrico.

Fonte: Elaborada pelo autor (2022).

Uma visão geral do interior do eletrocentro pode ser vista na Figura 54a, onde percebe-se, o inversor fotovoltaico no lado esquerdo, o painel elétrico com os circuitos das séries fotovoltaicas ao centro e, por fim, os módulos para aquisição das curvas I-V e o controlador no lado direito. A instalação do módulo para aquisição dos parâmetros climáticos, junto à estrutura da matriz fotovoltaica, é mostrada na Figura 54b. A instalação de um módulo comutador no interior do painel elétrico, entre as duas chaves seccionadoras, é apresentada na Figura 54c.

A validação do traçador de curvas I-V foi realizada através da comparação entre as curvas obtidas por este equipamento e as curvas rastreadas por um traçador de curvas comercial. O ensaio consistiu na aquisição de curvas I-V de uma única série fotovoltaica com um intervalo de poucos segundos entre as medições, o que garantiu que não houvessem variações climáticas significativas durante o ensaio. A configuração utilizada permitiu que as curvas pudessem ser comparadas (sobrepostas), sem a necessidade de um processo de conversão.

O traçador de curvas de curvas I-V comercial utilizado neste ensaio foi o PVA1000-S produzido pela Solmetric Corporation. Trata-se de um equipamento de referência no mercado global de traçadores de curvas I-V, sendo amplamente utilizado no comissionamento, na auditoria e nas tarefas de O&M de sistemas fotovoltaicos. O dispositivo possui a capacidade de rastrear as curvas I-V de arranjos fotovoltaicos com tensão de circuito aberto de até 1 kV e corrente de curto-circuito de até 20 A. A medição da tensão é realizada com a precisão de $\pm 0,5\% \pm 0,25$ V, enquanto a medição da corrente possui precisão de $\pm 0,5\% \pm 40$ mA.

O ensaio de validação foi realizado em campo, onde o traçador de curvas I-V proposto e o equipamento comercial registraram, cada um, cinco curvas I-V de uma mesma série fotovoltaica. O ensaio foi realizado durante um dia ensolarado, o que possibilitou que as curvas I-V pudessem ser adquiridas sob níveis distintos de irradiância e temperatura. As condições climáticas de cada ensaio foram mensuradas pelo equipamento comercial e são mostradas na Tabela 16.


Tabela 16 – Condições climáticas durante os ensaios de validação do traçador de curvas I-V.

Ensaio	Irradiância (W/m²)	Temperatura (°C)
1	610	34,9
2	711	37,5
3	782	38,3
4	912	37,4
5	1.087	40,1


Fonte: Elaborada pelo autor (2022).

A sobreposição das curvas I-V mensuradas durante os ensaios é mostrada na Figura 55. Destaca-se que a comparação entre os pontos de interesse das curvas adquiridas por ambos os equipamentos também auxilia na validação do traçador de curvas proposto. Assim sendo, apresenta-se a comparação da corrente de curto-circuito na Tabela 17, da tensão de circuito aberto na Tabela 18 e da potência máxima na Tabela 19.


Figura 55 – Curvas I-V adquiridas pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.




(a) Ensaio 1.




(b) Ensaio 2.



(c) Ensaio 3.



(d) Ensaio 4.



(e) Ensaio 5.

Fonte: Elaborada pelo autor (2022).

Tabela 17 – Corrente de curto-circuito adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.

Ensaio	Equipamento	Corrente de curto-circuito		
		Medida (A)	Erro absoluto (A)	Erro percentual (%)
1	PVA-1000S Protótipo	5,254	0,02	0,33
		5,271		
2	PVA-1000S Protótipo	6,149	0,04	0,58
		6,185		
3	PVA-1000S Protótipo	6,774	0,03	0,41
		6,802		
4	PVA-1000S Protótipo	7,909	0,05	0,67
		7,962		
5	PVA-1000S Protótipo	9,306	0,09	0,96
		9,396		

Fonte: Elaborada pelo autor (2022).

Tabela 18 – Tensão de circuito aberto adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.

Ensaio	Equipamento	Tensão de circuito aberto		
		Medida (V)	Erro absoluto (V)	Erro percentual (%)
1	PVA-1000S Protótipo	836,6	-3,28	-0,39
		833,3		
2	PVA-1000S Protótipo	834,7	-3,38	-0,41
		831,3		
3	PVA-1000S Protótipo	836,5	-3,56	-0,43
		832,9		
4	PVA-1000S Protótipo	844,4	-3,48	-0,41
		840,9		
5	PVA-1000S Protótipo	843,5	-3,03	-0,36
		840,5		

Fonte: Elaborada pelo autor (2022).

Tabela 19 – Potência máxima adquirida pelo traçador de curvas proposto e pelo PVA-1000S durante os ensaios de validação.

Ensaio	Equipamento	Potência máxima		
		Medida (W)	Erro absoluto (W)	Erro percentual (%)
1	PVA-1000S	3.335	-5,07	-0,15
	Protótipo	3.330		
2	PVA-1000S	3.872	0,76	0,02
	Protótipo	3.872		
3	PVA-1000S	4.257	-1,60	-0,04
	Protótipo	4.256		
4	PVA-1000S	4.978	14,98	0,30
	Protótipo	4.993		
5	PVA-1000S	5.771	23,15	0,40
	Protótipo	5.794		

Fonte: Elaborada pelo autor (2022).

5.3 VALIDAÇÃO DA METODOLOGIA PARA DIAGNÓSTICO DA GERAÇÃO FV

A metodologia proposta para diagnóstico da geração de usinas fotovoltaicas permite: detectar as situações de baixo desempenho em cada uma das séries FV, quantificar as perdas da geração e classificar as causas da degradação em sujidade, sombreamento parcial e condução dos diodos de *by-pass*. A seguir, os ensaios que foram realizados com o objetivo de validar a metodologia proposta são apresentados.

5.3.1 Validação da etapa de detecção


A detecção é a primeira etapa da metodologia proposta, ela é responsável por identificar se desempenho de cada uma das séries fotovoltaicas está adequado ou abaixo do esperado. Essa classificação é realizada pela comparação entre a potência máxima extraída da curva I-V medida e a potência máxima extraída da curva I-V estimada por um modelo fotovoltaico para as mesmas condições climáticas da curva medida.

As curvas I-V estimadas por um modelo matemático são obtidas através do Modelo Global Não-Linear (MGNL) que foi proposto Silva (2019), conforme está descrito na Seção 4.2. Para isso, em um primeiro momento, os quinze parâmetros que descrevem o MGNL devem ser estimados e esse processo exige um conjunto de seis curvas I-V. Vale ressaltar que essas curvas devem englobar um intervalo relevante de irradiância e temperatura, pois o MGNL permite reproduzir o comportamento físico das séries fotovoltaicas modeladas no mesmo intervalo de irradiância e temperatura das curvas utilizadas no treinamento do modelo.

O conjunto de curvas I-V utilizado na estimação dos parâmetros do MGNL é mostrado na Figura 56 e as condições climáticas de cada uma dessas curvas estão presentes na Tabela 20.

Destaca-se que, devido ao pré-processamento, os pontos de tensão das curvas foram divididos pela quantidade de módulos que compõem a série fotovoltaica (24). Além disso, a curva nº 3 foi utilizada como a curva de referência no processo de estimação dos parâmetros.

Figura 56 – Conjunto de curvas I-V utilizado na estimação dos parâmetros do MGNL.



Fonte: Elaborada pelo autor (2022).

Tabela 20 – Condições climáticas do conjunto de curvas I-V da Figura 56.

Curva I-V	Irradiância (W/m ²)	Temperatura (°C)
1	673	49,2
2	701	41,7
3	793	54,3
4	861	61,3
5	954	46,9
6	1.016	57,3

Fonte: Elaborada pelo autor (2022).

Os parâmetros do MGNL que foram estimados durante o processo de treinamento são mostrado na Tabela 21. Uma comparação entre curvas I-V medidas em campo pelo traçador de curvas I-V proposto e curvas estimadas pelo MGNL nas mesmas condições climáticas das curvas mensuradas é mostrada na Figura 48. Os pontos de interesse dessas curvas podem ser analisados através da Tabela 13. Por fim, vale enfatizar que as curvas I-V utilizadas no comparativo não foram utilizadas no treinamento do MGNL.

Tabela 21 – Parâmetros estimados pelo MGNL.

Parâmetro	Valor
Parcela da resistência série referente à irradiância (R_{sref1})	0,1912 Ω
Parcela da resistência série referente à temperatura (R_{sref2})	0,1912 Ω
Resistência paralela de referência (R_{pref})	66,26 Ω
Fator de idealidade de referência (A_{ref})	0,8023
Coefficiente de variação de I_{sc} com a temperatura (α_i)	3,4104 mA/ $^{\circ}$ C
Coefficiente de variação de V_{oc} com a temperatura (β_T)	-0,0927 V/ $^{\circ}$ C
Coefficiente de variação de V_{oc} com a irradiância (β_S)	1,6324
Coefficiente exponencial da irradiância para R_s (γ_{R_s})	-2,5149
Coefficiente exponencial da irradiância para R_p ($\gamma_{R_{ps}}$)	-3,9591
Coefficiente linear da temperatura para R_s (κ_{R_s})	0,0000%/ $^{\circ}$ C
Coefficiente linear da temperatura para R_p (κ_{R_p})	-1,3014%/ $^{\circ}$ C
Corrente de curto-circuito de referência (I_{scref})	7,5740 A
Tensão de circuito aberto de referência (V_{ocref})	33,5650

Fonte: Elaborada pelo autor (2023).

O autor Silva (2019) validou o MGNL através de algumas figuras de mérito, onde se destacam: o erro médio absoluto em potência normalizado (EMAPN) e o desvio médio quadrático da corrente normalizado (NRMSD). A Tabela 22 apresenta essas figuras mérito, assim como a diferença percentual do ponto de máxima potência da curva medida com a curva estimada para os quatro ensaios que foram mostrados na Figura 48.

Tabela 22 – Figuras de mérito do MGNL com base nos ensaios da Figura 48.

Figura de mérito	1ª Curva I-V	2ª Curva I-V	3ª Curva I-V	4ª Curva I-V
EMAPN (%)	2,0455	0,4083	10,7118	9,0673
RMSD (%)	1,9954	0,6766	8,5507	7,0730
ΔP_{mp} (%)	2,3391	2,0145	0,1954	2,1476


Fonte: Elaborada pelo autor (2023).

As séries fotovoltaicas de uma usina podem divergir ligeiramente em relação as suas características elétricas e devido ao processo de envelhecimento que não é uniforme. Portanto, os parâmetros do MGNL devem ser estimados individualmente para cada uma das séries FV. Assim sendo, a validação da etapa de detecção pode ser realizada em uma única série FV e o resultado ser estendido para as demais. Portanto, com o objetivo de validar a metodologia proposta, uma série FV foi submetida a distintas condições operacionais, conforme mostra a Figura 57.

Figura 57 – As situações operacionais que foram analisadas em uma série fotovoltaica.



(a) Detalhe de uma célula da série FV limpa.



(b) Detalhe de uma célula da série FV suja.



(c) Série FV limpa com uma fileira de células sombreada em cinco módulos.



(d) Série FV limpa com uma coluna de células sombreada em cinco módulos.



(e) Série FV limpa com duas células sombreadas em quatro módulos.



(f) Série FV limpa com duas células parcialmente sombreadas em cinco módulos.

Fonte: Elaborada pelo autor (2022).

Entre os ensaios realizados, um conjunto de 24 curvas I-V foi selecionado para analisar a capacidade da etapa de detecção da metodologia proposta. Os ensaios selecionados são:

- E1 - Limpa (L) e sem sombreamento (SS) (L-SS);
- E2 - Limpa e sem sombreamento (L-SS);
- E3 - Suja (S) e sem sombreamento (S-SS);
- E4 - Suja e sem sombreamento (S-SS);
- E5 - Limpa com uma fileira de células sombreadas (Fi) em um módulo (M) (L-1Fi-1M);
- E6 - Suja com uma fileira de células sombreadas em um módulo (S-1Fi-1M);
- E7 - Limpa com uma fileira de células sombreadas em cinco módulos (L-1Fi-5M);
- E8 - Suja com uma fileira de células sombreadas em cinco módulos (S-1Fi-5M);
- E9 - Limpa com uma coluna de células sombreadas (Co) em um módulo (L-1Co-1M);
- E10 - Suja com uma coluna de células sombreadas em um módulo (S-1Co-1M);
- E11 - Limpa com uma coluna de células sombreadas em cinco módulos (L-1Co-5M);
- E12 - Suja com uma coluna de células sombreadas em cinco módulos (S-1Co-5M);
- E13 - Limpa com duas células sombreadas (Ce) em um módulo (L-2Ce-1M);
- E14 - Suja com duas células sombreadas em um módulo (S-2Ce-1M);
- E15 - Limpa com duas células sombreadas em dois módulos (L-2Ce-2M);
- E16 - Suja com duas células sombreadas em dois módulos (S-2Ce-2M);
- E17 - Limpa com uma célula sombreada em um módulo (L-1Ce-1M);
- E18 - Suja com uma célula sombreada em um módulo (S-1Ce-1M);
- E19 - Limpa com uma célula sombreada em dois módulos (L-1Ce-2M);
- E20 - Suja com uma célula sombreada em dois módulos (S-1Ce-2M);
- E21 - Limpa e duas células parcialmente sombr. (CeP) em dois módulos (L-2CeP-2M);
- E22 - Suja e duas células parcialmente sombreadas em dois módulos (S-2CeP-2M);
- E23 - Limpa e duas células parcialmente sombreadas em cinco módulos (L-2CeP-5M);
- E24 - Suja e duas células parcialmente sombreadas em cinco módulos (S-2CeP-5M).

O sombreamento foi aplicado em células fotovoltaicas dispostas na horizontal (fileiras) e na vertical (colunas). O sombreamento de fileiras causa maior impacto na geração, pois são atingidas células dos três grupos que possuem um diodos de *by-pass* em paralelo. As condições de sombreamento foram impostas através da colocação de chapas de MDF e folhas de EVA sobre os módulos fotovoltaicos. A condição de sujidade ocorreu pelo processo natural, sendo que os módulos estavam em operação e expostos ao ambiente por cerca de 3 anos e 6 meses e nunca haviam sido limpos.


Na etapa de detecção, a identificação das situações de baixo desempenho ocorre através da comparação entre a potência máxima extraída da curva I-V mensurada com a potência máxima da curva I-V modelada. Logo, o MGNL é utilizado para gerar um conjunto de curvas I-V nas mesmas condições climáticas das curvas que foram mensuradas. As sobreposições entre essas curvas são mostradas nas Figuras 58, 59, 60 e 61.

A comparação entre a potência máxima medida (P_{max_med}) com a potência máxima modelada (P_{max_mod}), além de indicar o desempenho da série fotovoltaica, permite, de forma aproximada, quantificar as perdas da geração. A Tabela 23 mostra a condição climática presente no instante de cada ensaio, o valor da potência máxima da curva I-V mensurada e da curva modelada e a diferença percentual entre essas potências. Novamente, vale ressaltar que as potências foram divididas pela quantidade de módulos que compõem a série FV (24).


É necessário estabelecer um valor limiar para a potência (P_{max_lim}) antes de classificar o desempenho das séries fotovoltaicas. Afinal, a comparação direta entre P_{max_med} e P_{max_mod} pode implicar em alarmes falsos. Essa situação, conforme já descrito, decorre das incertezas das medições e do erro intrínseco presente nos modelos fotovoltaicos. A potência limiar também é responsável por evitar a ocorrência de alarmes por um nível mínimo de sujidade e/ou sombreamento. Por exemplo, em determinadas usinas fotovoltaicas, as perdas na faixa de 5% podem ser consideradas como toleráveis, já em outros casos, essa situação pode indicar a necessidade de intervenção da equipe de O&M. Portanto, a escolha de um valor para a potência limiar, que indica o baixo desempenho tolerável das séries fotovoltaicas, deve estar baseada em um conjunto de fatores que dependem das particularidades de cada usina e dos contratos de O&M.

A Tabela 23 apresenta P_{max_dif} que é a diferença percentual entre P_{max_med} e P_{max_mod} . Ao estabelecer heurísticamente o valor de 5% para a potência limiar, então os ensaios de nº 1, 2, 5, 9, 13, 17, 19, 21 e 23 estariam em conformidade com a potência esperada. Enquanto que os demais ensaios seriam classificados com desempenho abaixo do esperado. Conclui-se dessa análise que todos os ensaios realizados com a série FV cuja resultariam em desempenho abaixo do esperado. Além disso, evidenciou-se que ao sombrear uma fileira de células fotovoltaicas, os três conjuntos de células que possuem um diodo de *by-pass* em paralelo são atingidos e o desempenho da série fotovoltaica é reduzido significativamente. Ao final da etapa de detecção as curvas I-V classificadas com baixo desempenho são encaminhadas para a etapa de classificação.


Figura 58 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 1/4.




(a) E1: L-SS.




(b) E2: L-SS.




(c) E3: S-SS.



(d) E4: S-SS.




(e) E5: L-1Fi-1M.




(f) E6: S-1Fi-1M.

Fonte: Elaborada pelo autor (2022).


Figura 59 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 2/4.




(a) E7: L-1Fi-5M.




(b) E8: S-1Fi-5M.




(c) E9: L-1Co-1M.



(d) E10: S-1Co-1M.



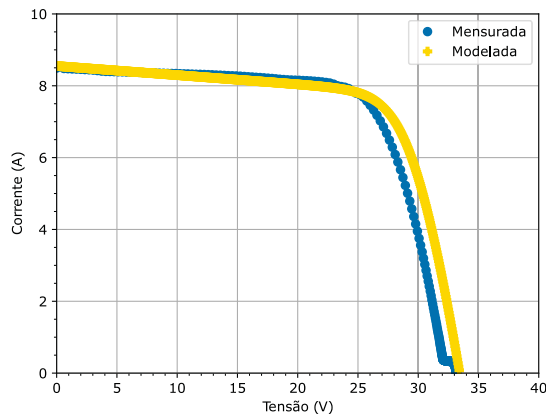
(e) E11: L-1Co-5M.




(f) E12: S-1Co-5M.

Fonte: Elaborada pelo autor (2022).


Figura 60 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 3/4.




(a) E13: L-2Ce-1M.




(b) E14: S-2Ce-1M.




(c) E15: L-2Ce-2M.



(d) E16: S-2Ce-2M.




(e) E17: L-1Ce-1M.




(f) E18: S-1Ce-1M.

Fonte: Elaborada pelo autor (2022).


Figura 61 – Comparação entre as curvas I-V mensuradas e modeladas sob distintas condições operacionais. Parte 4/4.




(a) E19: L-1Ce-2M.




(b) E20: S-1Ce-2M.




(c) E21: L-2CeP-2M.



(d) E22: S-2CeP-2M.



(e) E23: L-2CeP-5M.



(f) E24: S-2CeP-5M.

Fonte: Elaborada pelo autor (2022).

Tabela 23 – Parâmetros das curvas I-V apresentadas nas Figuras 58, 59, 60 e 61.

Ensaio nº	G (W/m ²)	T (°C)	P_{max_med} (W)	P_{max_mod} (W)	P_{max_dif} (%)
1	863	50,1	203,3	201,4	0,95
2	957	55,5	219,4	215,1	2,03
3	855	41,4	183,9	206,6	-10,97
4	955	57,9	190,3	212,6	-10,49
5	834	57,6	180,3	189,8	-4,99
6	838	52,2	166,0	194,7	-14,72
7	843	60,2	148,0	189,4	-21,84
8	865	55,0	137,6	198,1	-43,98
9	853	55,8	192,3	195,0	-1,36
10	860	53,0	176,8	198,6	-12,28
11	841	57,3	176,3	191,3	-8,52
12	847	52,8	163,0	196,0	-20,24
13	894	58,5	195,5	200,8	-2,71
14	870	54,4	173,7	199,6	-14,92
15	885	58,6	188,5	199,1	-5,66
16	855	54,4	165,0	196,5	-19,06
17	872	56,4	195,5	198,4	-1,48
18	877	52,6	178,1	202,3	-13,59
19	864	55,9	190,9	197,2	-3,28
20	864	51,9	173,0	200,2	-15,72
21	909	59,6	200,8	202,7	-0,94
22	911	58,9	178,4	203,7	-14,17
23	899	58,1	198,7	202,3	-1,78
24	924	59,2	178,1	205,8	-15,57

Fonte: Elaborada pelo autor (2022).

5.3.2 Validação da etapa de classificação

A etapa de classificação é responsável por processar as curvas I-V que foram identificadas com baixo desempenho na etapa anterior. Em um primeiro momento é realizada a identificação da causa da degradação, se ela está relacionada com a sujidade e/ou sombreamento. Por fim, ocorre a classificação da condição operacional das séries fotovoltaicas.

A identificação dos fatores de degradação é realizada por uma rede neural artificial do tipo *feedforward* de múltiplas camadas com a topologia 4-9-3. A RNA possui uma camada de entrada formada por quatro neurônios que representam os parâmetros normalizados e são obtidos através das Equações 30-33 (I_{scnorm} , V_{ocnorm} , I_{mpnorm} e V_{mpnorm}). A camada de saída da RNA é formada por três neurônios que identificam as situações de: i) sujidade, ii) sombreamento parcial e iii) condução dos diodos de *by-pass*.

Para validar a capacidade de classificação da RNA, empregou-se um conjunto formado pelas 24 curvas que foram utilizadas na validação da etapa de detecção e agregaram-se outras 76 curvas, o que totalizou um conjunto com 100 curvas I-V. Todas essas curvas foram mensuradas em uma única série fotovoltaica sob as seguintes condições operacionais:

1. Série FV limpa e sem sombreamento (20 curvas);
2. Série FV suja e sem sombreamento (20 curvas);
3. Série FV limpa e parcialmente sombreada com diodos de *by-pass* em condução (20 curvas);
4. Série FV suja e parcialmente sombreada com diodos de *by-pass* em condução (20 curvas);
5. Série FV limpa e parcialmente sombreada sem diodos de *by-pass* em condução (10 curvas);
6. Série FV suja e parcialmente sombreada sem diodos de *by-pass* em condução (10 curvas).

O subconjunto de curvas I-V que representam a série fotovoltaica parcialmente sombreada e com diodos de *by-pass* em condução (condições operacionais nº 3 e 4) é composto pelas curvas que foram adquiridas através dos seguintes ensaios:

- Série FV com uma fileira de células sombreadas em um, dois e cinco módulos;
- Série FV com uma coluna de células sombreadas em um, dois e cinco módulos;
- Série FV com duas células sombreadas em dois e quatro módulos;
- Série FV com uma célula sombreadas em dois e cinco módulos.

O subconjunto de curvas I-V que representam a série fotovoltaica parcialmente sombreada e sem diodos de *by-pass* em condução (condições operacionais nº 5 e 6) é composto pelas curvas que foram adquiridas através do seguinte ensaio:

- Série FV com duas células parcialmente sombreadas em dois, cinco e oito módulos.

A análise de desempenho da RNA consistiu em utilizar 70% das curvas I-V no treinamento da rede, enquanto que as demais curvas foram aplicadas apenas no processo de validação. A rede foi treinada com o algoritmo *backpropagation* e com a função de ativação sigmoide. Durante o treinamento, os pesos foram inicializados com valores aleatórios na faixa de -1 a 1 e foram realizados ensaios aplicando valores distintos para a constante de aprendizado e para o erro desejado - sendo este o único critério de parada que foi utilizado. A análise dos resultados permitiu concluir que os melhores resultados foram alcançados com a constante de aprendizado em 0,008 e o erro desejado em 0,05. Nesse caso, a RNA convergiu em cerca de 30 mil iterações.

Após o treinamento, o conjunto das curvas I-V restantes (30%) foi utilizado para validar a rede neural. O fato dessas curvas não serem empregadas no processo de treinamento garante

que os resultados obtidos na validação sejam idênticos aos que a rede fornecerá no dia a dia do monitoramento. Vale destacar que durante o treinamento, os neurônios assumiram o valor resultante da função sigmoide, sem nenhuma aproximação. Contudo, na etapa de validação, os resultados maiores que 0,5 foram considerados como um indicativo de presença (sim), enquanto que os resultados menores que 0,5 foram considerados como indicativo de ausência (não).

A capacidade de classificação da RNA pode ser aferida através de uma matriz de confusão, sendo essa uma ferramenta que indica os erros e os acertos da rede neural ao comparar as classificações preditas com os valores esperados. A matriz de confusão é formada pelos seguintes indicadores:

Verdadeiros positivos (VP) os casos em que a rede indicou SIM e o valor real é SIM.

Verdadeiros negativos (VN) os casos em que a rede indicou NÃO e o valor real é NÃO.

Falsos positivos (FP) os casos em que a rede indicou SIM e o valor real é NÃO.

Falsos negativos (FN) os casos em que a rede indicou NÃO e o valor real é SIM.

A disposição dos indicadores *VP*, *VN*, *FP* e *FN* em uma matriz de confusão está ilustrada na Figura 62a. A matriz de confusão para cada um dos neurônios da camada de saída da RNA proposta é mostrada nas Figuras 62b, 62c e 62d.

A literatura apresenta algumas métricas que podem ser utilizadas para avaliar a capacidade de classificação de uma rede neural. No entanto, uma RNA pode fornecer resultados satisfatórios quando avaliado através de uma métrica, mas pode fornecer resultados insatisfatórios quando avaliado através de outras métricas (MISHRA, 2018). Logo, torna-se essencial que a RNA proposta seja avaliada por um conjunto de métricas.

A acurácia (*Ac*) é uma métrica que representa a porcentagem de elementos classificados corretamente e indica a performance geral do modelo. No caso da RNA proposta, a acurácia global é determinada por:

$$Ac = \frac{VP + VN}{VP + VN + FP + FN} = \frac{45 + 44}{45 + 44 + 1 + 0} = 0,989 \quad (35)$$

essa métrica é ideal se a quantidade de amostras pertencentes a cada classe é igual.

A precisão (*Pr*) é uma outra métrica que pode ser avaliada e, nesse caso, indica quais das situações classificadas pela rede neural como positivas, realmente eram verdadeiras. A precisão global da RNA é dada por:

$$Pr = \frac{VP}{VP + FP} = \frac{45}{45 + 1} = 0,978 \quad (36)$$

o valor calculado para a precisão foi semelhante ao determinado para a acurácia, o que indica o equilíbrio da rede neural.

Figura 62 – Matrizes de confusão para a RNA proposta.

Real \ RNA	Sim	Não
Sim	VP	FN
Não	FP	VN

(a) Matriz de confusão para referência dos termos *VP*, *VN*, *FP* e *FN*.

Real \ RNA	Sujo	Não sujo
Sujo	15	0
Não sujo	0	15

(b) Matriz de confusão da classe que indica a sujidade.

Real \ RNA	Sombreado	Não sombreado
Sombreado	18	0
Não sombreado	1	11

(c) Matriz de confusão da classe que indica o sombreado.

Real \ RNA	Diodos conduzem	Diodos não conduzem
Diodos conduzem	12	0
Diodos não conduzem	0	18

(d) Matriz de confusão da classe que indica condução dos diodos de *by-pass*.

Fonte: Elaborada pelo autor (2022).

Ao contrário da precisão, a revocação (*Re*) é uma métrica que indica quais dentre as situações realmente verdadeiras foram classificadas como positivas pela rede. A revocação global da RNA pode ser calculada por:

$$Re = \frac{VP}{VP + FN} = \frac{45}{45 + 0} = 1,0 \quad (37)$$

percebe-se que todas as situações onde houve sujidade, sombreado e condução dos diodos de *by-pass* foi identificada pela rede neural.

Equilibrar uma boa precisão com uma boa revocação exige bastante trabalho, na maioria dos casos, o aperfeiçoamento da revocação causa a redução da precisão (ou vice-versa). Um classificador perfeito, aquele que não comete nenhum erro, apresenta a precisão e a revocação com valor unitário. No entanto, em um mundo real isso é algo quase impossível de se atingir.

A métrica *F1* combina a precisão e a revocação ao calcular um número que indica a qualidade geral do classificador. No caso da RNA proposta, essa métrica é calculada por:

$$F1 = 2 \cdot \frac{Pr \cdot Re}{Pr + Re} = 2 \cdot \frac{0,978 \cdot 1,0}{0,978 + 1,0} = 0,989 \quad (38)$$

A análise das métricas permite concluir que a RNA proposta possui uma excelente capacidade de classificação. Contudo, analisar apenas esses indicadores pode não ser suficiente, o importante é compreender os resultados que foram obtidos. O processo de treinamento mostrou que, das 30 curvas I-V analisadas, apenas uma não foi classificada corretamente. Sendo que, ao invés da RNA classificar a série fotovoltaica como suja, a classificação indicou que, além da sujidade havia sombreamento parcial. Na prática, em ambas as situações, a série FV estaria suja e necessitaria passar por um processo de limpeza. Logo, por mais que a RNA tenha cometido um erro de classificação, o mesmo possivelmente não impactaria de forma tão significativa nas atividades de O&M.

5.4 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Esse capítulo apresentou a validação do traçador de curvas I-V que foi proposto no Capítulo 3 deste trabalho e da metodologia para diagnóstico da geração de usinas fotovoltaicas que foi proposta no Capítulo 4. Uma usina com potência nominal de 100 kW recebeu a instalação do traçador de curvas e teve a sua geração diagnosticada conforme a metodologia proposta.

A usina fotovoltaica utilizada nos ensaios de validação é composta por 384 módulos e está localizada na Universidade Federal de Santa Maria. A matriz da usina está dividida em 16 séries e cada uma possui 24 módulos com potência de 270 W. O traçador de curvas I-V foi instalado no eletrocentro da usina que está construído junto a matriz fotovoltaica.

A validação do traçador de curvas I-V ocorreu através da comparação entre as curvas I-V adquiridas pelo equipamento proposto e as curvas rastreadas por um equipamento comercial, o PVA1000-S, produzido pela Solmetric Corporation. O ensaio foi realizado durante um dia ensolarado e cada um dos equipamentos registrou cinco curvas I-V, de uma mesma série fotovoltaicas, sob níveis distintos de irradiância e temperatura. Destaca-se que, para uma curva I-V adquirida sob irradiância de 1.087 W/m^2 , o equipamento proposto mensurou 5.794 W e o comercial 5.771 W no ponto de máxima potência, um erro percentual de apenas 0,398%.

Por fim, ocorreu a validação da metodologia para diagnóstico da geração de usinas fotovoltaicas. Em um primeiro momento foram realizados alguns ensaios em uma série fotovoltaica que permitiu registrar os impactos da sujidade e do sombreamento parcial nas curvas I-V. A primeira etapa da metodologia foi validada através da comparação entre a potência máxima extraída das curvas I-V mensuradas e a potência máxima extraída das curvas estimadas por um modelo fotovoltaico. Por fim, na segunda etapa, uma rede neural do tipo *perceptron* multicamadas foi utilizada para identificar os fatores de degradação. A RNA foi treinada com 70 curvas I-V e validada com outras 30 curvas. A rede alcançou a acurácia de 0,989, a precisão de 0,978 e a revocação de 1,0.

6 CONCLUSÕES

Atualmente, devido a consolidação das fontes solares, as atividades de Operação e Manutenção (O&M) estão ganhando destaque e demonstrando a sua importância para o aumento da confiabilidade e, conseqüentemente, da rentabilidade dos projetos fotovoltaicos. No entanto, monitorar e avaliar o desempenho de instalações fotovoltaicas não é uma tarefa trivial, pois existem dificuldades que são inerentes a esse processo.

A geração fotovoltaica depende da irradiação solar, o que a torna suscetível aos movimentos de rotação e translação da Terra, além de ser impactada pela presença de nuvens e de componentes contaminantes na atmosfera que afetam a translucidez do ar. Por sua vez, os módulos fotovoltaicos, apesar de não disporem de peças mecânicas, estão suscetíveis a uma série de fatores que podem degradar a geração. Inclusive, existem fatores naturais que impactam na geração e são intrínsecos a todas as instalações fotovoltaicas, como a degradação induzida pela luz (LID), a sujidade e o sombreamento.

O mercado já percebeu essa demanda e oferta um significativo conjunto de soluções para o monitoramento fotovoltaico. Contudo, a maioria desses dispositivos operam como um agregador de dados. Em outras palavras, são equipamentos que apenas armazenam dados elétricos e climáticos, mas não possuem a capacidade de avaliar o desempenho dos arranjos fotovoltaicos. Por outro lado, a literatura dispõe de um extenso referencial teórico sobre diversas técnicas de monitoramento e avaliação de desempenho de instalações fotovoltaicas. Entre essas técnicas, destacam-se, o uso dos métodos estatísticos, a análise de curvas I-V, a termografia e a eletroluminescência.

A análise da curva I-V é uma excelente métrica para avaliar o desempenho de instalações fotovoltaicas. Trata-se de uma das medições mais completas e que permite identificar as situações de baixo desempenho, assim como, as causas da degradação. Inclusive, já existem soluções comerciais para a execução desses ensaios. No entanto, a maioria dos traçadores de curvas I-V comerciais são equipamentos manuais, o que impossibilita o seu uso no monitoramento contínuo de usinas e ainda expõem o operador a riscos de choque elétrico.

Com o objetivo de contribuir com as atividades de O&M, este trabalho propôs um traçador de curvas I-V automático e integrado a usinas fotovoltaicas. O equipamento proposto possibilita a aquisição automática da curva I-V de cada uma das séries fotovoltaicas que compõem o arranjo. Além disso, permite o acesso remoto as curvas mensuradas. As características do equipamento propiciam que usinas, sem uma equipe de O&M em campo, sejam monitoradas de forma contínua e com a qualidade que esse tipo de ensaio oferece.

A topologia do traçador de curvas I-V proposto é formada pelos módulos comutadores, o módulo para aquisição das curvas I-V, o módulo para aquisição dos parâmetros climáticos e o módulo controlador. Os comutadores são instalados em cada uma das séries fotovoltaicas e possuem o papel de definir o fluxo da energia elétrica que provém dos módulos fotovoltaicos. Em outras palavras, esses dispositivos realizam a conexão/desconexão das séries FV com o inversor

e com o módulo para aquisição das curvas I-V.

O módulo para aquisição das curvas I-V utiliza uma carga capacitiva para rastrear as curvas. Sendo esse, o método mais utilizado quando objetiva-se a aquisição de curvas I-V de geradores fotovoltaicos com alta potência. Os capacitores podem ser empregados nesse processo devido a sua capacidade de emular o comportamento de um resistor variável.

As curvas I-V sempre devem vir acompanhadas das condições climáticas que estão presentes no instante dos ensaios. Logo, projetou-se um módulo para a medição da irradiância solar no plano inclinado, através de uma célula fotovoltaica de referência. Esse mesmo módulo é responsável por medir a temperatura de operação dos módulos fotovoltaicos, o que ocorre através de uma termorresistência fixada na parte traseira de um módulo FV.

A comunicação entre os módulos que compõem o traçador de curvas é realizada por meio de um barramento RS-485 com o protocolo Modbus RTU. O controle das tarefas que envolvem a aquisição das curvas I-V, assim como o armazenamento das curvas é realizado pelo módulo controlador. Além disso, esse módulo realiza a exportação das curvas mensuradas para um servidor remoto que pode ser local ou estar na nuvem.

A análise das curvas I-V demanda tempo e exige um significativo conhecimento técnico por parte dos operadores. Logo, este trabalho também propôs uma metodologia para diagnosticar a geração de usinas fotovoltaicas de forma automática. O método realiza a análise individual de desempenho de cada uma das séries FV da usina e permite identificar as situações de baixo desempenho e classificar a condição operacional das séries. O resultado do diagnóstico também pode ser acessado remotamente, o que viabiliza a operação de usinas sem uma equipe de O&M no local, ou a operação com uma equipe reduzida para agir quando for diagnosticada uma situação de baixo desempenho. O método proposto é dividido em duas etapas: a detecção e a classificação.

A etapa de detecção é responsável por identificar se o desempenho das séries fotovoltaicas está em conformidade com o esperado. Essa tarefa é realizada pela comparação entre a potência máxima extraída das curvas I-V mensuradas em campo com potência máxima extraída de curvas estimadas por um modelo matemático. No caso, optou-se pelo uso do Modelo Global Não-Linear (MGNL), sendo esse um modelo baseado em circuito elétrico e que destaca-se pela sua capacidade em reproduzir o comportamento de módulos FV sobre uma ampla faixa de irradiância e temperatura. Ao detectar uma condição de baixo desempenho é realizada a quantificação das perdas, o que ocorre por meio da comparação entre a potência máxima medida e a potência máxima esperada.

A etapa de classificação é responsável por processar apenas as curvas I-V que foram classificadas com desempenho abaixo do esperado. Nessa etapa ocorre a identificação dos fatores de degradação e a classificação das condições operacionais de cada série FV. A identificação dos fatores de degradação é realizada através de uma rede neural artificial do tipo *perceptron* multicamadas com topologia 4-9-3. A camada de entrada da RNA é composta por quatro neurônios que representam os parâmetros normalizados da corrente de curto-circuito, da tensão

de circuito aberto, da corrente e da tensão no ponto de máxima potência. A camada de saída da RNA possui três neurônios que indicam a sujidade, o sombreamento parcial e a condução dos diodos de *by-pass*.

Com o objetivo de validar as propostas desta tese em uma situação real, não apenas em escala laboratorial, o traçador de curvas I-V e a metodologia para avaliação de desempenho foram instalados em uma usina fotovoltaica de 100 kW. A usina está localizada na Universidade Federal de Santa Maria no Rio Grande do Sul e possui um arranjo com 384 módulos fotovoltaicos divididos em 16 séries fotovoltaicas.

A validação do traçador de curvas foi realizada pela comparação entre as curvas I-V adquiridas pelo equipamento proposto e as curvas rastreadas por um traçador comercial. No caso foi utilizado o PVA1000-S, sendo esse um equipamento de referência no mercado global de traçadores de curvas I-V. O ensaio consistiu em obter as curvas I-V de uma mesma série FV com os dois equipamentos em um curto período, o que possibilitou a sobreposição das curvas. Os ensaios foram realizados sob a irradiância de 610 W/m², 711 W/m², 782 W/m², 912 W/m² e 1.087 W/m². Os resultados mostraram a alta capacidade de concordância entre os equipamentos. No caso do ponto de máxima potência, a diferença percentual entre as curvas rastreadas por cada um dos equipamentos foi de -0,15% para o primeiro ensaio, 0,02% para o segundo, -0,04% para o terceiro, 0,30% para o quarto e 0,40% para o quinto.

A validação da metodologia para diagnóstico da geração também foi realizada na usina fotovoltaica. Nesse caso, uma série fotovoltaica foi submetida a condições de sujidade e sombreamento parcial com o objetivo de identificar essas situações através do método proposto. Em um primeiro momento, na etapa de detecção, a comparação entre as curvas I-V mensuradas e as curvas modeladas mostrou que, até mesmo, os pequenos sombreamentos já causam alterações nas curvas I-V. Por exemplo, ao considerar uma série FV com 24 módulos e cada módulo com 60 células, uma situação de sombreamento parcial de duas células em apenas dois módulos, já possibilitou a identificação do sombreamento pelo método proposto.

A etapa de classificação foi validada através da análise de desempenho de uma RNA que foi proposta para identificar os fatores de degradação. Nesse caso, um conjunto de 100 curvas I-V foi utilizado no ensaio. Sendo, 70 curvas para o treinamento e 30 para a validação. Verificou-se que, a RNA apresentou uma boa capacidade de classificação com a acurácia de 0,989, a precisão de 0,978 e a revocação de 1,0. Do conjunto de validação, apenas uma curva I-V não foi classificada corretamente. Sendo que essa curva indicava uma condição de sujidade da série FV e foi classificada como sendo sujidade acrescida de sombreamento. Portanto, trata-se de uma classificação incorreta, mas que não afetaria de forma significativa o cronograma de O&M.

Por fim, conclui-se que, as propostas desta tese se enquadram na demanda do setor fotovoltaico em relação a busca por soluções automáticas e inteligentes para o monitoramento e diagnóstico da geração de usinas fotovoltaicas. Os resultados alcançados demonstram as contribuições para os protocolos de O&M, através da minimização dos custos e a maximização da geração fotovoltaica.

6.1 TRABALHOS FUTUROS

A seguir, são sugeridas algumas oportunidades de trabalhos futuros que estendem ou adaptam as contribuições que foram propostas nesta pesquisa. São elas:

- Propor uma topologia para a instalação do traçador de curvas I-V em arranjos fotovoltaicos que utilizam conversores integrados à módulos fotovoltaicos ou microinversores. Sugere-se uma investigação sobre a viabilidade de integrar o traçador de curvas nesses conversores.
- Investigar outros métodos de otimização para a compilação do MGNL. A versão original do modelo foi proposta em ambiente Matlab e fez uso do algoritmo *Pattern search*. Neste trabalho, o MGNL foi convertido para o ambiente Python e apresentou dificuldades em modelar o joelho da curva I-V sob irradiância elevada. Sugere-se, a busca por algoritmos de otimização que possam melhorar a resposta do MGNL nessas situações. Vale citar, os algoritmos *Guaranteed Convergence Particle Swarm Optimization* (GCPSO) e o *Directed Searching Optimization Algorithm* (DSO) que já apresentaram bons resultados na estimação dos parâmetros do MGNL.
- Avaliar a possibilidade de utilizar outros modelos fotovoltaicos, em especial os modelos baseados em inteligência artificial. Destaca-se o uso da IA generativa, como o ChatGPT, que utiliza a tecnologia para criar conteúdo original.
- Elaborar uma estratégia para estimar a potência limiar automaticamente. Não é recomendada a comparação direta entre a potência máxima mensurada nas curvas I-V e a potência máxima modelada com o intuito de identificar o baixo desempenho. Afinal, existe um custo fixo das manutenções corretivas e outras particularidades de cada usina que devem ser consideradas antes de deslocar uma equipe de O&M. Sugere-se, a elaboração de um algoritmo inteligente para determinar automaticamente o valor da potência limiar.
- Aperfeiçoar as estratégias de classificação dos fatores de degradação. A RNA proposta para essa tarefa apresentou excelentes resultados de classificação. No entanto, a etapa de treinamento pode restringir o seu uso em aplicações comerciais. Sugere-se a busca por outras ferramentas de classificação, ou então, o uso de dados modelados no treinamento. No caso de modelar as degradações é possível gerar centenas de curvas por simulação e aplicá-las no treinamento da RNA, ao invés de utilizar poucas curvas I-V experimentais.
- Expandir a capacidade de identificação dos fatores de degradação. A metodologia proposta foi treinada para reconhecer as situações mais corriqueiras de baixo desempenho, com a sujidade e o sombreamento parcial. Sugere-se a expansão do método proposto para o reconhecimento de outros fatores de degradação, como a LID e o PID.

6.2 PUBLICAÇÕES DO AUTOR ASSOCIADAS À TESE DE DOUTORADO

Em relação a publicação de artigos científicos, os seguintes artigos, pertinentes ao tema do trabalho, foram publicados em anais de congressos:

- TRETER, Marcos Eduardo; MEZARROBA, Marcello; MICHELS, Leandro. Modelagem matemática do comportamento elétrico de módulos fotovoltaicos: Uma revisão. VIII Congresso Brasileiro de Energia Solar, 2020, Fortaleza.
- TRETER, Marcos Eduardo; MICHELS, Leandro. Métodos de aquisição experimental de curvas I-V de arranjos fotovoltaicos: Uma revisão. 11th Seminar on Power Electronics and Control - SEPOC, 2018, Santa Maria.

REFERÊNCIAS

- ABE, Caio Felipe et al. Simplified approach to adjust iec-60891 equation coefficients from experimental measurements with long-term validation. **IEEE Journal of Photovoltaics**, IEEE, v. 11, n. 2, p. 496–503, 2020. Citado na página 72.
- ADDABBO, Pia et al. A uav infrared measurement approach for defect detection in photovoltaic plants. In: IEEE. **2017 IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace)**. [S.l.], 2017. p. 345–350. Citado na página 30.
- ADDABBO, Pia et al. Uav system for photovoltaic plant inspection. **IEEE Aerospace and Electronic Systems Magazine**, IEEE, v. 33, n. 8, p. 58–67, 2018. Citado na página 30.
- AHMED, Ahsan et al. Investigation of pv utilizability on university buildings: A case study of karachi, pakistan. **Renewable Energy**, Elsevier, v. 195, p. 238–251, 2022. Citado na página 77.
- AKRAM, Mohd Nafis; LOTFIFARD, Saeed. Modeling and health monitoring of dc side of photovoltaic array. **IEEE Transactions on Sustainable energy**, IEEE, v. 6, n. 4, p. 1245–1253, 2015. Citado na página 26.
- ALAM, Mohammed Khorshed et al. A comprehensive review of catastrophic faults in pv arrays: types, detection, and mitigation techniques. **IEEE Journal of Photovoltaics**, IEEE, v. 5, n. 3, p. 982–997, 2015. Citado na página 55.
- ALI, Mohamed Hassan et al. Real time fault detection in photovoltaic systems. **Energy Procedia**, Elsevier, v. 111, p. 914–923, 2017. Citado na página 28.
- ALI, Saddam et al. A comprehensive study of 18–19 years field aged modules for degradation rate determination along with defect detection and analysis using ir, el, uv. In: IEEE. **2018 15th International Bhurban Conference on Applied Sciences and Technology (IBCAST)**. [S.l.], 2018. p. 28–35. Citado na página 36.
- ALMADHOR, Ahmad. Performance prediction of distributed pv generation systems using artificial neural networks (ann) and mesh networks. In: IEEE. **2018 International Conference on Smart Grid (icSmartGrid)**. [S.l.], 2018. p. 88–91. Citado na página 79.
- AMIRY, H et al. Design and implementation of a photovoltaic iv curve tracer: Solar modules characterization under real operating conditions. **Energy Conversion and Management**, Elsevier, v. 169, p. 206–216, 2018. Citado 2 vezes nas páginas 41 e 42.
- ANDERSON, AJ. **Photovoltaic translation equations: A new approach. Final subcontract report**. [S.l.], 1996. Citado na página 71.
- ANDÒ, Bruno et al. Sentinella: Smart monitoring of photovoltaic systems at panel level. **IEEE Transactions on Instrumentation and Measurement**, IEEE, v. 64, n. 8, p. 2188–2199, 2015. Citado na página 35.
- AYODELE, TR; OGUNJUYIGBE, ASO; EKO, EE. Evaluation of numerical algorithms used in extracting the parameters of a single-diode photovoltaic model. **Sustainable Energy Technologies and Assessments**, Elsevier, v. 13, p. 51–59, 2016. Citado na página 86.
- BABU, B Chitti; GURJAR, Suresh. A novel simplified two-diode model of photovoltaic (pv) module. **IEEE journal of photovoltaics**, IEEE, v. 4, n. 4, p. 1156–1161, 2014. Citado na página 84.

BAI, Jianbo et al. Development of a new compound method to extract the five parameters of pv modules. **Energy Conversion and Management**, Elsevier, v. 79, p. 294–303, 2014. Citado na página 86.

BAPTISTA, Dario et al. Hardware implementation of an artificial neural network model to predict the energy production of a photovoltaic system. **Microprocessors and Microsystems**, Elsevier, v. 49, p. 77–86, 2017. Citado 2 vezes nas páginas 79 e 135.

BARBI, Ivo. **Eletrônica de potência: Projetos de fontes chaveadas**. [S.l.]: Edição do autor, 2014. Citado na página 96.

BEDRICH, Karl G et al. Quantitative electroluminescence imaging analysis for performance estimation of pid-influenced pv modules. **IEEE Journal of Photovoltaics**, IEEE, v. 8, n. 5, p. 1281–1288, 2018. Citado na página 31.

BEGA, Egídio Alberto. **Instrumentação industrial**. [S.l.]: Interciência, 2011. Citado na página 59.

BENATTO, Gisele Alves dos Reis et al. Drone-based daylight electroluminescence imaging of pv modules. **IEEE Journal of Photovoltaics**, IEEE, v. 10, n. 3, p. 872–877, 2020. Citado na página 31.

BRADASCHIA, Fabricio et al. Parameter identification for pv modules based on an environment-dependent double-diode model. **IEEE Journal of Photovoltaics**, IEEE, v. 9, n. 5, p. 1388–1397, 2019. Citado na página 84.

BRANO, Valerio Lo et al. An improved five-parameter model for photovoltaic modules. **Solar Energy Materials and Solar Cells**, Elsevier, v. 94, n. 8, p. 1358–1370, 2010. Citado na página 86.

CÁCERES, Manuel et al. Low-cost i–v tracer for pv modules under real operating conditions. **Energies**, Multidisciplinary Digital Publishing Institute, v. 13, n. 17, p. 4320, 2020. Citado 2 vezes nas páginas 41 e 42.

CALLEJO, Luis Hernández; SAAVEDRA, Sara Gallardo; GÓMEZ, Víctor Alonso. A review of photovoltaic systems: Design, operation and maintenance. **Solar Energy**, Elsevier, v. 188, p. 426–440, 2019. Citado 5 vezes nas páginas 21, 22, 23, 29 e 38.

CHEDDADI, Youssef et al. Design and implementation of an intelligent low-cost iot solution for energy monitoring of photovoltaic stations. **SN Applied Sciences**, Springer, v. 2, p. 1–11, 2020. Citado na página 35.

CHEN, Zhicong et al. Development of a capacitor charging based quick iv curve tracer with automatic parameter extraction for photovoltaic arrays. **Energy Conversion and Management**, Elsevier, v. 226, p. 113521, 2020. Citado 4 vezes nas páginas 40, 41, 42 e 86.

CHI, HB et al. Internet of things (iot) based iv curve tracer for photovoltaic monitoring systems. **Indones. J. Electr. Eng. Comput. Sci.**, v. 13, n. 3, p. 1022–1030, 2019. Citado 2 vezes nas páginas 41 e 42.

CHIANTORE, Paolo V.; PAPAECONOMOU, Vassilis; DEGENER, Stefan. **Operations & Maintenance Best Practices Guidelines (Version3.0)**. [S.l.], 2018. Citado 8 vezes nas páginas 23, 29, 31, 36, 52, 57, 59 e 60.

CHINE, W et al. A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. **Renewable Energy**, Elsevier, v. 90, p. 501–512, 2016. Citado na página 26.

CUNNINGHAM, Joseph; HERNDAY, Paul; MOKRI, James. **Commissioning for PV Performance - SunSpec Alliance Best Practice Guide**. [S.l.], 2014. Citado 8 vezes nas páginas 28, 30, 31, 59, 63, 64, 65 e 73.

DAVARIFAR, M et al. Real-time model base fault diagnosis of pv panels using statistical signal processing. In: IEEE. **2013 International Conference on Renewable Energy Research and Applications (ICRERA)**. [S.l.], 2013. p. 599–604. Citado na página 25.

DHIMISH, Mahmoud. Defining the best-fit machine learning classifier to early diagnose photovoltaic solar cells hot-spots. **Case Studies in Thermal Engineering**, Elsevier, v. 25, p. 100980, 2021. Citado na página 26.

DUBARD, J et al. Photovoltaic module performance measurements traceability: Uncertainties survey. **Measurement**, Elsevier, v. 51, p. 451–456, 2014. Citado na página 61.

DUCANGE, Pietro et al. An intelligent system for detecting faults in photovoltaic fields. In: IEEE. **2011 11th International Conference on Intelligent Systems Design and Applications**. [S.l.], 2011. p. 1341–1346. Citado na página 80.

DUNN, Lawrence; GOSTEIN, Michael; STUEVE, William. **System and methods for high-precision string-level measurement of photovoltaic array performance**. 2012. Citado na página 45.

DURAN, E et al. A new application of the buck-boost-derived converters to obtain the iv curve of photovoltaic modules. In: IEEE. **2007 IEEE Power Electronics Specialists Conference**. [S.l.], 2007. p. 413–417. Citado na página 69.

DURAN, E et al. Different methods to obtain the i–v curve of pv modules: A review. In: IEEE. **2008 33rd IEEE Photovoltaic Specialists Conference**. [S.l.], 2008. p. 1–6. Citado 4 vezes nas páginas 65, 66, 68 e 69.

ERKAYA, Yunus; MOSES, Paul; MARSILLAC, Sylvain. On-site characterization of pv modules using a portable, mosfet-based capacitive load. In: IEEE. **2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)**. [S.l.], 2016. p. 3119–3122. Citado na página 67.

FOTOVOLT. Sistemas de monitoramento de instalações de energia fotovoltaica. **Revista FotoVolt**, Aranda Editora, n. 31, p. 42–45, 2020. Citado na página 24.

FRIESEN, Gabi et al. Photovoltaic module energy yield measurements: Existing approaches and best practice. **Report IEA-PVPS T13-11**, 2018. Citado 5 vezes nas páginas 57, 58, 59, 61 e 64.

GALLAS, Márcia Russman. Incerteza de medição. **Texto baseado no Guia Para a Expressão da Incerteza de Medição, 2a edição, ABNT, INMETRO**, 1998. Citado na página 61.

GARCÍA-VALVERDE, Rafael et al. Portable and wireless iv-curve tracer for > 5 kv organic photovoltaic modules. **Solar Energy Materials and Solar Cells**, Elsevier, v. 151, p. 60–65, 2016. Citado 2 vezes nas páginas 41 e 42.

GAROUDJA, Elyes et al. Statistical fault detection in photovoltaic systems. **Solar Energy**, Elsevier, v. 150, p. 485–499, 2017. Citado na página 33.

- GASTLI, A; BEN-BRAHIM, L; RHOUMA, MBH. Ann-based extraction approach of pv cell equivalent circuit parameters. In: IEEE. **2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe)**. [S.l.], 2015. p. 1–10. Citado na página 87.
- GILLELAND, Braden; HOBBS, William B; RICHARDSON, Joseph B. High throughput detection of cracks and other faults in solar pv modules using a high-power ultraviolet fluorescence imaging system. In: IEEE. **2019 IEEE 46th Photovoltaic Specialists Conference (PVSC)**. [S.l.], 2019. p. 2575–2582. Citado na página 32.
- GONZÁLEZ, Isaías; PORTALO, José María; CALDERÓN, Antonio José. Configurable iot open-source hardware and software iv curve tracer for photovoltaic generators. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 21, n. 22, p. 7650, 2021. Citado 2 vezes nas páginas 41 e 42.
- GRIMACCIA, Francesco et al. Survey on pv modules' common faults after an o&m flight extensive campaign over different plants in italy. **IEEE Journal of Photovoltaics**, IEEE, v. 7, n. 3, p. 810–816, 2017. Citado na página 30.
- GROVER, Frederick W. **Inductance calculations: working formulas and tables**. [S.l.]: Courier Corporation, 2004. Citado na página 93.
- GUPTA, Abhishek Kumar; CHAUHAN, Narendra Singh; SAXENA, Ravi. Real time iv and pv curve tracer using labview. In: IEEE. **2016 International Conference on Innovation and Challenges in Cyber Security ICICCS-INBUSH**. [S.l.], 2016. p. 265–269. Citado na página 65.
- HALWACHS, M et al. Statistical evaluation of pv system performance and failure data among different climate zones. **Renewable Energy**, Elsevier, v. 139, p. 1040–1060, 2019. Citado na página 23.
- HAN, Jinsoo et al. Low-cost monitoring of photovoltaic systems at panel level in residential homes based on power line communication. **IEEE Transactions on Consumer Electronics**, IEEE, v. 63, n. 4, p. 435–441, 2017. Citado na página 33.
- HANSEN, Clifford W; STEIN, Joshua; LUKETA-HANLIN, Amanda. **SENSITIVITY OF SINGLE DIODE MODELS FOR PHOTOVOLTAIC MODULES TO METHOD USED FOR PARAMETER ESTIMATION**. [S.l.], 2013. Citado 2 vezes nas páginas 36 e 85.
- HARIHARAN, R et al. A method to detect photovoltaic array faults and partial shading in pv systems. **IEEE Journal of Photovoltaics**, IEEE, v. 6, n. 5, p. 1278–1285, 2016. Citado na página 36.
- HARROU, Fouzi et al. Reliable fault detection and diagnosis of photovoltaic systems based on statistical monitoring approaches. **Renewable energy**, Elsevier, v. 116, p. 22–37, 2018. Citado na página 38.
- HARROU, Fouzi; TAGHEZOUIT, Bilal; SUN, Ying. Robust and flexible strategy for fault detection in grid-connected photovoltaic systems. **Energy conversion and management**, Elsevier, v. 180, p. 1153–1166, 2019. Citado na página 33.
- HAYKIN, Simon. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001. Citado na página 135.

HERRMANN, Werner et al. Iea pvps task 13 - performance, operation and reliability of photovoltaic systems. In: **Qualification of Photovoltaic (PV) Power Plants using Mobile Test Equipment**. [S.l.: s.n.], 2021. Citado 2 vezes nas páginas 31 e 32.

HERRMANN, W et al. Qualification of photovoltaic (pv) power plants using mobile test equipment. **IEA-PVPS T13-24: 2021**, 2021. Citado na página 62.

HIRATA, Youichi et al. Diagnosis photovoltaic failure by simple function method to acquire i-v curve of photovoltaic modules string. In: IEEE. **2012 38th IEEE Photovoltaic Specialists Conference**. [S.l.], 2012. p. 1340–1343. Citado na página 28.

HUANG, Jun-Ming; WAI, Rong-Jong; YANG, Geng-Jie. Design of hybrid artificial bee colony algorithm and semi-supervised extreme learning machine for pv fault diagnoses by considering dust impact. **IEEE Transactions on Power Electronics**, IEEE, v. 35, n. 7, p. 7086–7099, 2019. Citado na página 28.

HUIXIN, Peng. **Photovoltaic board output characteristic curve tester**. [S.l.]: CN206922717, 2017. Citado na página 44.

IBIRRIAGA, Julen Joseba Maestro et al. Low-cost, high flexibility i-v curve tracer for photovoltaic modules. In: IEEE. **2010 12th International Conference on Optimization of Electrical and Electronic Equipment**. [S.l.], 2010. p. 1210–1215. Citado na página 67.

IBRAHIM, Ibrahim Anwar et al. An improved wind driven optimization algorithm for parameters identification of a triple-diode photovoltaic cell model. **Energy Conversion and Management**, Elsevier, v. 213, p. 112872, 2020. Citado 3 vezes nas páginas 84, 86 e 87.

IRENA, International Renewable Energy Agency. Global energy transformation: A roadmap to 2050 (2019 edition). 2019. Citado na página 21.

ISHAQUE, Kashif; SALAM, Zainal. An improved modeling method to determine the model parameters of photovoltaic (pv) modules using differential evolution (de). **Solar energy**, Elsevier, v. 85, n. 9, p. 2349–2359, 2011. Citado 2 vezes nas páginas 86 e 87.

JIANG, Lian Lian; MASKELL, Douglas L. Automatic fault detection and diagnosis for photovoltaic systems using combined artificial neural network and analytical based methods. In: IEEE. **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2015. p. 1–8. Citado na página 79.

JOGLEKAR, Ashish Vasant. **Online I-V tracer for per string monitoring and maintenance of photovoltaic (PV) panels**. 2020. Citado na página 45.

JOGLEKAR, Ashish V; HEGDE, Balachandra. Online iv tracer for per string monitoring and maintenance of pv panels. In: IEEE. **IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society**. [S.l.], 2018. p. 1890–1894. Citado na página 45.

JOGLEKAR, Vasant. **Online i-v tracer for per string monitoring and maintenance of photovoltaic (pv) panels**. [S.l.]: IN201841037650, 2019. Citado na página 44.

JONES, C Birk et al. Comparative review of high resolution monitoring versus standard inverter data acquisition for a single photovoltaic power plant. In: IEEE. **2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC)(A Joint Conference of 45th IEEE PVSC, 28th PVSEC & 34th EU PVSEC)**. [S.l.], 2018. p. 0715–0720. Citado 3 vezes nas páginas 29, 74 e 75.

- JORDEHI, A Rezaee. Parameter estimation of solar photovoltaic (pv) cells: A review. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 61, p. 354–371, 2016. Citado 3 vezes nas páginas 83, 86 e 87.
- KAIZUKA, Izumi et al. Snapshot of global pv markets 2022. **International Energy Agency PVPS**, 2022. Citado na página 21.
- KANJIAN, Zhang; ZIYANG, Ye; ZENGXIANG, He. **System and method for remotely acquiring output characteristic curve of photovoltaic cell**. [S.l.]: CN113489458, 2021. Citado na página 43.
- KARATEPE, Engin; HIYAMA, Takashi et al. Controlling of artificial neural network for fault diagnosis of photovoltaic array. In: IEEE. **2011 16th International Conference on Intelligent System Applications to Power Systems**. [S.l.], 2011. p. 1–6. Citado 2 vezes nas páginas 80 e 134.
- KELLEN, Gillispe; PETER, Wrisley. **Wireless current-voltage tracer with uninterrupted bypass system and method**. [S.l.]: US8952715, 2012. Citado na página 44.
- KERSTEN, Friederike et al. Degradation of multicrystalline silicon solar cells and modules after illumination at elevated temperature. **Solar Energy Materials and Solar Cells**, Elsevier, v. 142, p. 83–86, 2015. Citado na página 52.
- KHALID, Ahmad Mohd et al. Performance ratio—crucial parameter for grid connected pv plants. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 65, p. 1139–1158, 2016. Citado 2 vezes nas páginas 35 e 58.
- KHALIL, Ihsan Ullah et al. Comparative analysis of photovoltaic faults and performance evaluation of its detection techniques. **IEEE Access**, IEEE, v. 8, p. 26676–26700, 2020. Citado 2 vezes nas páginas 54 e 56.
- KHAN, Muhammad Faisal Nadeem et al. A review of estimating solar photovoltaic cell parameters. In: IEEE. **2019 2nd International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)**. [S.l.], 2019. p. 1–6. Citado na página 82.
- KHATIB, Tamer; ELMENREICH, Wilfried; MOHAMED, Azah. Simplified iv characteristic tester for photovoltaic modules using a dc-dc boost converter. **Sustainability**, Multidisciplinary Digital Publishing Institute, v. 9, n. 4, p. 657, 2017. Citado 2 vezes nas páginas 41 e 42.
- KOHNO, Tohru et al. Fault-diagnosis architecture for large-scale photovoltaic power plants that does not require additional sensors. **IEEE Journal of Photovoltaics**, IEEE, v. 9, n. 3, p. 780–789, 2019. Citado na página 34.
- KORKMAZ, Deniz; ACIKGOZ, Hakan. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 113, p. 104959, 2022. Citado na página 30.
- KULAKSIZ, AA. Anfis-based parameter estimation of one-diode equivalent circuit model of pv modules. In: IEEE. **2011 IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI)**. [S.l.], 2011. p. 415–420. Citado na página 87.

KUMAR, Nallapaneni Manoj; ATLURI, Karthik; PALAPARTHI, Sriteja. Internet of things (iot) in photovoltaic systems. In: IEEE. **2018 National Power Engineering Conference (NPEC)**. [S.l.], 2018. p. 1–4. Citado na página 34.

KWOFIE, Ekow Appiah; MENSAH, Godfred; ANTWI, Vincent Safo. Post commission grid impact assessment of a 20 mwp solar pv grid connected system on the ecg 33 kv network in winneba. In: IEEE. **2019 IEEE PES/IAS PowerAfrica**. [S.l.], 2019. p. 521–526. Citado na página 35.

LEVA, Sonia et al. Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. **Mathematics and computers in simulation**, Elsevier, v. 131, p. 88–100, 2017. Citado na página 80.

LI, Baojie et al. Fault diagnosis of photovoltaic panels using full i–v characteristics and machine learning techniques. **Energy Conversion and Management**, Elsevier, v. 248, p. 114785, 2021. Citado na página 28.

LI, Xiaoxia et al. An unmanned inspection system for multiple defects detection in photovoltaic plants. **IEEE Journal of Photovoltaics**, IEEE, v. 10, n. 2, p. 568–576, 2019. Citado na página 30.

LILLO-BRAVO, Isidoro et al. Impact of energy losses due to failures on photovoltaic plant energy balance. **Energies**, Multidisciplinary Digital Publishing Institute, v. 11, n. 2, p. 363, 2018. Citado na página 56.

LIU, Haitao. Power rating uncertainty analysis of electrical performance of photovoltaic modules. In: IEEE. **IEEE PES Innovative Smart Grid Technologies**. [S.l.], 2012. p. 1–4. Citado na página 61.

LOPEZ-GUEDE, Jose Manuel et al. Systematic modeling of photovoltaic modules based on artificial neural networks. **International Journal of Hydrogen Energy**, Elsevier, v. 41, n. 29, p. 12672–12687, 2016. Citado na página 79.

LORENZO, Gianfranco Di et al. Review of o&m practices in pv plants: Failures, solutions, remote control, and monitoring tools. **IEEE Journal of Photovoltaics**, IEEE, v. 10, n. 4, p. 914–926, 2020. Citado 5 vezes nas páginas 22, 38, 54, 55 e 56.

LU, Xiaoyang et al. Efficient fault diagnosis approach for solar photovoltaic array using a convolutional neural network in combination of generative adversarial network under small dataset. **Solar Energy**, Elsevier, v. 253, p. 360–374, 2023. Citado na página 27.

MAO, Wang et al. A research on power line communication based on parallel resonant coupling technology in pv module monitoring. **IEEE Transactions on Industrial Electronics**, IEEE, v. 65, n. 3, p. 2653–2662, 2017. Citado na página 33.

MARES, Oana; PAULESCU, Marius; BADESCU, Viorel. A simple but accurate procedure for solving the five-parameter model. **Energy Conversion and Management**, Elsevier, v. 105, p. 139–148, 2015. Citado na página 86.

MARTINS, Denizar et al. **Curve tracer and portable electrical characterizer for testing photovoltaic modules**. [S.l.]: BR102019020934, 2019. Citado na página 44.

MASSON, G; KAIZUKA, I et al. Trends in photovoltaic applications 2019. 2019. Citado 2 vezes nas páginas 22 e 50.

MAZHARI, B. An improved solar cell circuit model for organic solar cells. **Solar energy materials and solar cells**, Elsevier, v. 90, n. 7-8, p. 1021–1033, 2006. Citado na página 85.

MEKKI, H; MELLIT, Adel; SALHI, H. Artificial neural network-based modelling and fault detection of partial shaded photovoltaic modules. **Simulation Modelling Practice and Theory**, Elsevier, v. 67, p. 1–13, 2016. Citado 2 vezes nas páginas 26 e 79.

MELLIT, A. et al. An embedded system for remote monitoring and fault diagnosis of photovoltaic arrays using machine learning and the internet of things. **Renewable energy**, Elsevier, 2023. ISSN 0960-1481. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S096014812300397X>>. Citado na página 27.

MELLIT, Adel; KALOGIROU, Soteris A. Anfis-based modelling for photovoltaic power supply system: A case study. **Renewable energy**, Elsevier, v. 36, n. 1, p. 250–258, 2011. Citado 3 vezes nas páginas 77, 80 e 81.

MISHRA, Aditya. **Metrics to Evaluate your Machine Learning Algorithm**. 2018. Acessado: 19/11/2022. Disponível em: <<https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>>. Citado na página 160.

MITTAL, Manan et al. Performance prediction of pv module using electrical equivalent model and artificial neural network. **Solar Energy**, Elsevier, v. 176, p. 104–117, 2018. Citado 3 vezes nas páginas 82, 83 e 84.

MORAIS, José. **ESP32 – Analisando e corrigindo o ADC interno**. 2019. <<https://www.embarcados.com.br/esp32-adc-interno/>>. Acessado em: 12/05/2022. Citado na página 105.

MORALES-ARAGONÉS, José Ignacio et al. Low-cost electronics for online iv tracing at photovoltaic module level: Development of two strategies and comparison between them. **Electronics**, Multidisciplinary Digital Publishing Institute, v. 10, n. 6, p. 671, 2021. Citado 2 vezes nas páginas 41 e 42.

MORLIER, Arnaud et al. Influence of environmental conditions on uv fluorescence imaging in the field. In: IEEE. **2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC)(A Joint Conference of 45th IEEE PVSC, 28th PVSEC & 34th EU PVSEC)**. [S.l.], 2018. p. 1309–1312. Citado na página 31.

MUÑOZ-CERÓN, E et al. Influence of operation and maintenance expenditures in the feasibility of photovoltaic projects: The case of a tracking pv plant in Spain. **Energy policy**, Elsevier, v. 121, p. 506–518, 2018. Citado na página 22.

MURDOCK, Hannah E et al. Renewables 2020: Global status report. 2020. Citado na página 22.

MURDOCK, Hannah E et al. Renewables 2021-global status report. 2021. Citado na página 22.

MURDOCK, Hannah E et al. Renewables 2022: Global status report. 2022. Citado na página 21.

MUSTAFA, Zain et al. Fault identification for photovoltaic systems using a multi-output deep learning approach. **Expert Systems with Applications**, Elsevier, v. 211, p. 118551, 2023. Citado na página 27.

NISHIOKA, Kensuke et al. Analysis of multicrystalline silicon solar cells by modified 3-diode equivalent circuit model taking leakage current through periphery into consideration. **Solar energy materials and solar cells**, Elsevier, v. 91, n. 13, p. 1222–1227, 2007. Citado na página 84.

NOVUS. **Número máximo de dispositivos na rede RS485**. 2011. <https://www.novus.com.br/site/default.asp?Idioma=55&TroncoID=053663&SecaoID=273506&SubsecaoID=0&Template=../artigosnoticias/user_exibir.asp&ID=949222.YmQqZUD1pco.link>. Acessado em: 23/04/2022. Citado na página 91.

OPREA, Matei I et al. Detection of potential induced degradation in c-si pv panels using electrical impedance spectroscopy. In: IEEE. **2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)**. [S.l.], 2016. p. 1575–1579. Citado na página 32.

OPREA, Simona-Vasilica et al. Photovoltaic power plants (pv-pp) reliability indicators for improving operation and maintenance activities. a case study of pv-pp agiea located in romania. **IEEE Access**, IEEE, v. 7, p. 39142–39157, 2019. Citado 2 vezes nas páginas 23 e 33.

PADMAVATHI, K; DANIEL, S Arul. Performance analysis of a 3 mwp grid connected solar photovoltaic power plant in india. **Energy for Sustainable Development**, Elsevier, v. 17, n. 6, p. 615–625, 2013. Citado na página 35.

PEREIRA, Renata IS et al. Iot embedded linux system based on raspberry pi applied to real-time cloud monitoring of a decentralized photovoltaic plant. **Measurement**, Elsevier, v. 114, p. 286–297, 2018. Citado na página 34.

PEREIRA, Renata IS; JUCÁ, Sandro CS; CARVALHO, Paulo CM. Iot embedded systems network and sensors signal conditioning applied to decentralized photovoltaic plants. **Measurement**, Elsevier, v. 142, p. 195–212, 2019. Citado na página 34.

PEREIRA, Thiago A et al. Design of a portable photovoltaic i–v curve tracer based on the dc–dc converter method. **IEEE Journal of Photovoltaics**, IEEE, v. 11, n. 2, p. 552–560, 2021. Citado 2 vezes nas páginas 41 e 42.

PHOTOVOLTAIC system performance - Part 1: Monitoring. Geneva, Switzerland, 2017. Citado 3 vezes nas páginas 58, 59 e 60.

PLATON, Radu et al. Online fault detection in pv systems. **IEEE Transactions on Sustainable Energy**, IEEE, v. 6, n. 4, p. 1200–1207, 2015. Citado na página 36.

QUATER, Paolo Bellezza et al. Light unmanned aerial vehicles (uavs) for cooperative inspection of pv plants. **IEEE Journal of Photovoltaics**, IEEE, v. 4, n. 4, p. 1107–1113, 2014. Citado na página 54.

RAMAPRABHA, R et al. Design and implementation of efficient curve tracer for photovoltaic system under partial shaded conditions. **International Journal on Electrical Engineering and Informatics**, School of Electrical Engineering and Informatics, Bandung Institute of . . . , v. 7, n. 1, p. 140, 2015. Citado 3 vezes nas páginas 40, 41 e 42.

- REISE, C et al. Uncertainties in pv system yield predictions and assessments. **IEA-PVPS, Report IEA-PVPS T13-12**, 2018. Citado na página 61.
- RETORNO, Mais. **Z-score: saiba o que é e como funciona**. 2022. <<https://maisretorno.com/portal/termos/z/z-score>>. Acessado em: 12/04/2023. Citado na página 123.
- REZK, Hegazy et al. Performance of data acquisition system for monitoring pv system parameters. **Measurement**, Elsevier, v. 104, p. 204–211, 2017. Citado na página 50.
- RICHTER, Mauricio et al. Best practice guide on uncertainty in pv modelling. **Public report Performance Plus WP2 Deliverable D**, v. 2, 2015. Citado na página 61.
- RIVAI, Ahmad; RAHIM, Nasrudin Abd. Binary-based tracer of photovoltaic array characteristics. **IET Renewable Power Generation**, IET, v. 8, n. 6, p. 621–628, 2014. Citado na página 65.
- ROSA, Thales; SOUTO, Olívio. A influência da sujidade no desempenho de sistemas fotovoltaicos. **Revista FotoVolt**, Aranda Editora, n. 39, p. 26–31, 2021. Citado na página 52.
- RUMELHART, David E; HINTON, Geoffrey E; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986. Citado na página 138.
- SAINI, Navdeep et al. Design of microcontroller based i–v plotter using igbt electronic load. In: IEEE. **2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)**. [S.l.], 2016. p. 1–5. Citado na página 68.
- SAMARA, Sufyan; NATSHEH, Emad. Intelligent real-time photovoltaic panel monitoring system using artificial neural networks. **IEEE Access**, IEEE, v. 7, p. 50287–50299, 2019. Citado na página 79.
- SARIKH, Salima et al. Implementation of a plug and play iv curve tracer dedicated to characterization and diagnosis of pv modules under real operating conditions. **Energy Conversion and Management**, Elsevier, v. 209, p. 112613, 2020. Citado 2 vezes nas páginas 41 e 42.
- SAYYAD, Javed; NASIKKAR, Paresh. Design and development of low cost, portable, on-field iv curve tracer based on capacitor loading for high power rated solar photovoltaic modules. **IEEE Access**, IEEE, v. 9, p. 70715–70731, 2021. Citado 7 vezes nas páginas 41, 42, 66, 67, 69, 70 e 104.
- SAYYAD, Javed K; NASIKKAR, Paresh S. Capacitor load based i–v curve tracer for performance characterisation of the solar photovoltaic system. **Applied Solar Energy**, Springer, v. 56, n. 3, p. 168–177, 2020. Citado 2 vezes nas páginas 41 e 42.
- SEAWARD. **Photovoltaic System Commissioning and Testing A Guide for PV System Technicians and Engineers**. [S.l.], 2012. Citado 7 vezes nas páginas 49, 50, 51, 52, 53, 62 e 70.
- SERA, Dezso; TEODORESCU, Remus; RODRIGUEZ, Pedro. Pv panel model based on datasheet values. In: IEEE. **2007 IEEE international symposium on industrial electronics**. [S.l.], 2007. p. 2392–2396. Citado na página 86.

SERA, Dezso; TEODORESCU, Remus; RODRIGUEZ, Pedro. Photovoltaic module diagnostics by series resistance monitoring and temperature and rated power estimation. In: **IEEE. 2008 34th Annual Conference of IEEE Industrial Electronics**. [S.l.], 2008. p. 2195–2199. Citado na página 26.

SHAH, Syed Faizan Ali; KHAN, Irfan A; KHAN, Hassan Abbas. Performance evaluation of two similar 100mw solar pv plants located in environmentally homogeneous conditions. **IEEE Access**, IEEE, v. 7, p. 161697–161707, 2019. Citado na página 52.

SHAPSOUGH, Salsabeel et al. An iot-based remote iv tracing system for analysis of city-wide solar power facilities. **Sustainable Cities and Society**, Elsevier, v. 57, p. 102041, 2020. Citado 2 vezes nas páginas 41 e 42.

SHARMA, Renu; GOEL, Sonali. Performance analysis of a 11.2 kwp roof top grid-connected pv system in eastern india. **Energy Reports**, Elsevier, v. 3, p. 76–84, 2017. Citado na página 35.

SHARMA, Vikrant; CHANDEL, SS. Performance analysis of a 190 kwp grid interactive solar photovoltaic power plant in india. **Energy**, Elsevier, v. 55, p. 476–485, 2013. Citado 2 vezes nas páginas 35 e 76.

SHELEMBE, Linda; BARENDSE, Paul. Online condition monitoring of photovoltaic (pv) cells by implementing electrical impedance spectroscopy using a switch-mode dc-dc converter. In: **IEEE. 2020 IEEE Energy Conversion Congress and Exposition (ECCE)**. [S.l.], 2020. p. 2136–2141. Citado na página 32.

SHUKLA, Akash Kumar; SUDHAKAR, K; BARENDAR, Prashant. Simulation and performance analysis of 110 kwp grid-connected photovoltaic system for residential building in india: A comparative analysis of various pv technology. **Energy Reports**, Elsevier, v. 2, p. 82–88, 2016. Citado na página 76.

SILVA, Emerson Alves da. Proposta de um modelo global não-linear para caracterização do comportamento elétrico de células fotovoltaicas. Universidade Federal de Pernambuco, 2019. Citado 7 vezes nas páginas 126, 127, 128, 130, 141, 148 e 150.

SILVA, Hugo. **PID & LID: Devastating Phenomena for PV plants**. 2015. <<https://sinovoltaics.com/quality-control/pid-lid-devastating-phenomena-pv-plants/>>. Acessado em: 25/10/2022. Citado na página 52.

SILVA, Italo Ferreira et al. Plotting characteristic curves of photovoltaic modules: A simple and portable approach. **IEEE Industry Applications Magazine**, IEEE, v. 27, n. 3, p. 63–72, 2021. Citado 2 vezes nas páginas 41 e 42.

SILVA, Ivan Nunes Da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas curso prático. **São Paulo: Artliber**, 2010. Citado 2 vezes nas páginas 77 e 78.

SILVA, Michelle Kitayama da; GUL, Mehreen Saleem; CHAUDHRY, Hassam. Review on the sources of power loss in monofacial and bifacial photovoltaic technologies. **Energies**, MDPI, v. 14, n. 23, p. 7935, 2021. Citado na página 52.

SILVESTRE, Santiago et al. New procedure for fault detection in grid connected pv systems based on the evaluation of current and voltage indicators. **Energy Conversion and Management**, Elsevier, v. 86, p. 241–249, 2014. Citado na página 34.

SOON, Jing Jun; LOW, Kay-Soon; GOH, Shu Ting. Multi-dimension diode photovoltaic (pv) model for different pv cell technologies. In: IEEE. **2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE)**. [S.l.], 2014. p. 2496–2501. Citado na página 85.

SPATARU, Sergiu et al. Monitoring and fault detection in photovoltaic systems based on inverter measured string iv curves. In: WIP WIRTSCHAFT UND INFRASTRUKTUR GMBH & CO PLANUNGS KG. **31st European Photovoltaic Solar Energy Conference and Exhibition**. [S.l.], 2015. p. 1667–1674. Citado na página 28.

SPERTINO, Filippo et al. Capacitor charging method for i–v curve tracer and mppt in photovoltaic systems. **Solar Energy**, Elsevier, v. 119, p. 461–473, 2015. Citado 4 vezes nas páginas 40, 41, 42 e 64.

STEIN, Joshua. **PV Performance Modeling Methods and Practices**. [S.l.], 2017. Citado 4 vezes nas páginas 52, 53, 56 e 61.

SUSKIS, Pavels; GALKIN, Ilya. Enhanced photovoltaic panel model for matlab-simulink environment considering solar cell junction capacitance. In: IEEE. **IECON 2013-39th Annual Conference of the IEEE Industrial Electronics Society**. [S.l.], 2013. p. 1613–1618. Citado na página 84.

TACIUC, Mircea. An experimental system for measuring the pv panel characteristics curves under real operation conditions. In: IEEE. **2016 International Symposium on Fundamentals of Electrical Engineering (ISFEE)**. [S.l.], 2016. p. 1–6. Citado na página 68.

TRIKI-LAHIANI, Asma; ABDELGHANI, Afef Bennani-Ben; SLAMA-BELKHODJA, Ilhem. Fault detection and monitoring systems for photovoltaic installations: A review. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 82, p. 2680–2692, 2018. Citado 3 vezes nas páginas 55, 56 e 60.

VERGURA, S; MARINO, F; CARPENTIERI, M. Processing infrared image of pv modules for defects classification. In: IEEE. **2015 International Conference on Renewable Energy Research and Applications (ICRERA)**. [S.l.], 2015. p. 1337–1341. Citado na página 29.

VINTURINI, Mateus. **O efeito PID e sua ação sobre os módulos fotovoltaicos**. 2019. Acessado: 09/03/2022. Disponível em: <<https://canalsolar.com.br/o-efeito-pid-e-sua-acao-sobre-os-modulos-fotovoltaicos/>>. Citado na página 54.

VIOTTO, Michael; HOPF, Markus; SCHROPP, Bernhard. **Method for determining a characteristic curve of a photovoltaic (pv) string, dc/dc converter, and photovoltaic system suitable for carrying out the method**. [S.l.]: WO2020/254029, 2019. Citado na página 43.

WALKER, H et al. **Model of Operation-and-Maintenance Costs for Photovoltaic Systems**. [S.l.], 2020. Citado na página 22.

WANG, Meng-Hui; LIN, Zong-Han; LU, Shiue-Der. A fault detection method based on cnn and symmetrized dot pattern for pv modules. **Energies**, MDPI, v. 15, n. 17, p. 6449, 2022. Citado na página 27.

WARNER, TH; III, CH Cox. A high power current-voltage curve tracer employing a capacitive load. **Solar Cells**, Elsevier, v. 7, n. 1-2, p. 175–181, 1982. Citado 2 vezes nas páginas 65 e 66.

WILLOUGHBY, Alexander A; OSINOWO, Muritala O. Development of an electronic load iv curve tracer to investigate the impact of harmattan aerosol loading on pv module performance in southwest nigeria. **Solar Energy**, Elsevier, v. 166, p. 171–180, 2018. Citado 2 vezes nas páginas 41 e 42.

XIA, Kun et al. A real-time monitoring system based on zigbee and 4g communications for photovoltaic generation. **CSEE Journal of Power and Energy Systems**, CSEE, v. 6, n. 1, p. 52–63, 2020. Citado na página 36.

YANFEI, Yu; HUA, Ni; ZONGJUN, Yang. **Photovoltaic module output characteristic curve obtaining circuit and method and photovoltaic power generation system**. [S.l.]: CN108832894, 2018. Citado na página 44.

YUAN, Zixia; XIONG, Guojiang; FU, Xiaofan. Artificial neural network for fault diagnosis of solar photovoltaic systems: A survey. **Energies**, MDPI, v. 15, n. 22, p. 8693, 2022. Citado na página 27.

ZHAO, Tiefu; BHAVARAJU, Vijay; THEISEN, Peter. Hybrid dc switch for solar array fault protection. In: IEEE. **2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC)**. [S.l.], 2015. p. 1–6. Citado na página 96.

ZHICONG, Chen et al. **Distributed photovoltaic module string and module iv characteristic curve on-line measurement system**. [S.l.]: CN106357220, 2016. Citado na página 44.

ZHICONG, Chen et al. **Photovoltaic array iv characteristic curve scanning and parameter identification system and method**. [S.l.]: CN108111125, 2018. Citado na página 44.

ZHU, Y; XIAO, W. A comprehensive review of topologies for photovoltaic i–v curve tracer. **Solar Energy**, Elsevier, v. 196, p. 346–357, 2020. Citado na página 69.