

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E
GESTÃO DO CONHECIMENTO - PPGI

AGENOR RORIS FILHO

Modelagem e simulação de arranjos de painéis fotovoltaicos para predição de condições operacionais usando curvas I-V e redes neurais convolucionais

São Paulo
2024

AGENOR RORIS FILHO

Modelagem e simulação de arranjos de painéis fotovoltaicos para predição de condições operacionais usando curvas I-V e redes neurais convolucionais

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI) da Universidade Nove de Julho (UNINOVE), como requisito parcial para a obtenção do grau de Mestre em Informática e Gestão do Conhecimento.

Prof. Orientador: Dr. Cleber Gustavo Dias

São Paulo

2024

Roris Filho, Agenor.

Modelagem e simulação de arranjos de painéis fotovoltaicos para predição de condições operacionais usando curvas I-V e redes neurais convolucionais. / Agenor Roris Filho. 2024.

115 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2024.

Orientador (a): Prof. Dr. Cleber Gustavo Dias.

1. Análise de perdas e falhas. 2. Curvas I-V. 3. Energia solar. 4. Modelagem. 5. Simulação. 6. Predição de defeitos. 7. Redes neurais convolucionais. 8. Sistemas fotovoltaicos.

I. Dias, Cleber Gustavo. II. Título.

CDU 004

PARECER – EXAME DE DEFESA


Parecer da Comissão Examinadora designada para o exame de defesa do Programa de Pós-Graduação em Informática e Gestão do Conhecimento a qual se submeteu o aluno Agenor Roris Filho.

Tendo examinado o trabalho apresentado para obtenção do título de "Mestre em Informática e Gestão do Conhecimento", com Dissertação intitulada "Modelagem e simulação de arranjos de painéis fotovoltaicos para predição de condições operacionais usando curvas I-V e redes neurais convolucionais", a Comissão Examinadora considerou o trabalho:


☒) Aprovado	☐) Aprovado condicionalmente
☐) Reprovado com direito a novo exame	☐) Reprovado

EXAMINADORES

Prof. Dr. Cleber Gustavo Dias - Uninove (Orientador)



Prof. Dr. Eduardo Crestana Guardia - UNIFEI (Membro Externo)



Prof. Dr. André Felipe Henriques Librantz - UNINOVE (Membro Interno)



Prof. Dr. Peterson Adriano Belan - UNINOVE (Membro Interno)



São Paulo, 19 de fevereiro de 2024

AGRADECIMENTOS

Agradeço à Universidade Nove de Julho (UNINOVE), através do seu Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI), pela bolsa de estudo e apoio no aprimoramento da formação profissional e pesquisa acadêmica no Brasil, bem como à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) do Ministério da Educação, pela ajuda de custo. Agradeço aos diretores, funcionários e professores e ao meu orientador pela confiança, compartilhamento de objetivos e conhecimento e todo o apoio durante a realização dos estudos e pesquisas. E, finalmente, agradeço à minha família, esposa e filhos, pelo apoio e paciência durante todo o período em que priorizei os estudos, sem os quais esse trabalho não seria possível.

RESUMO

O crescimento dos investimentos em energias renováveis, como a energia solar, faz crescer a busca por sistemas de geração mais confiáveis e rentáveis. O monitoramento do funcionamento desses sistemas a fim de analisar eventuais perdas na potência gerada, bem como identificar anomalias e suas possíveis causas, é uma das alternativas, sendo os métodos automatizados, inclusive os apoiados em algoritmos de aprendizado de máquina, cada vez mais relevantes neste cenário. Essa pesquisa resultou num modelo de rede neural convolucional (RNC) capaz de identificar se a condição operacional de um sistema fotovoltaico (SFV), está normal ou sob alguma anomalia. O modelo foi treinado utilizando imagens digitais com os gráficos resultantes do traçado do comportamento da tensão em função da corrente elétrica gerada (curva I-V), produzidos através da modelagem matemática e simulação computacional do funcionamento de um circuito equivalente do SFV. Foram avaliadas isoladamente ou combinadas as condições normais, de *mismatch* (tolerância nos parâmetros elétricos em função dos métodos e materiais de fabricação, degradação pela idade ou por eventos ou agentes externos, entre outros), curto-circuito, circuito aberto e sombreamento parcial. A fim de garantir ampla utilização e oferecer adequada precisão na identificação da condição operacional, o trabalho foi desenvolvido nos mais variados cenários, com diversos arranjos de dezenas de painéis fotovoltaicos operando sob diversas temperaturas e irradiâncias, resultando na geração de centenas de milhares de imagens das respectivas curvas características I-V. Foram obtidos resultados significativos demonstrando que a modelagem proposta e o modelo de RNC desenvolvido oferecem capacidade de generalização para diferentes tipos de painéis fotovoltaicos, operando numa ampla faixa de temperaturas e irradiâncias.

Palavras-chave: análise de perdas e falhas, curvas I-V, energia solar, modelagem, simulação, predição de defeitos, redes neurais convolucionais, sistemas fotovoltaicos.

ABSTRACT

The growth of investments in renewable energies, especially solar energy, increases the search for more reliable and profitable generation systems. Monitoring the operation of these systems in order to analyze power losses, as well as to identify anomalies and their possible causes, is one of the alternatives, and automated methods, including those supported by machine learning algorithms, are increasingly relevant in this scenario. This research resulted in a convolutional neural network (CNN) model, capable of identifying whether the operating condition of a photovoltaic system (PV system) is normal or under some anomaly. The model was trained using digital images with the graphs of the voltage behavior as a function of the electric current generated (I-V curve), produced through mathematical modeling and simulation of the operation of a PV system's equivalent circuit. operation of a PV system's equivalent circuit. Normal operational condition, mismatch (tolerance in electrical parameters depending on manufacturing methods and materials, degradation due to age or external events or agents, etc.), short circuit, open circuit, and partial shading were evaluated alone or combined. In order to ensure wide use and offer adequate precision in the identification of the operating condition, the work was developed in the most varied scenarios, with several arrangements of dozens of photovoltaic panels operating under various temperatures and radiations, resulting in the generation of hundreds of thousands of images of the respective characteristic curves I-V. Significant results were obtained demonstrating that the proposed modeling method and the CNN model offer generalization capacity for different types of photovoltaic panels, operating in a wide range of temperatures and radiations.

Keywords: convolutional neural networks, I-V curves, fault detection; losses analysis, modeling, simulation; solar power, PV systems.

LISTA DE ILUSTRAÇÕES

Figura 1: Detalhes de usina fotovoltaica em Minas Gerais.	17
Figura 2: Exemplo de curva I-V sob diversas condições.....	18
Figura 3: Ligação de painéis num inversor com MMT.....	20
Figura 4: Geração fotovoltaica distribuída por classe de consumo	21
Figura 5: Geração fotovoltaica total e matriz elétrica brasileira	22
Figura 6: Potência outorgada por fonte de geração Total / Em construção.	22
Figura 7 – Evolução de artigos relacionados ao tema.....	24
Figura 8 – Principais autores entre 2013-2023: análise de perdas e falhas.....	30
Figura 9 – Principais autores entre 2013-2023: perdas e falhas usando RNC.....	30
Figura 10 – Distribuição das citações (CiteScore) de acordo com a fonte.	31
Figura 11 – Irradiação solar e ângulos relevantes.....	32
Figura 12 – Exemplo de painéis: mono e policristalino.	33
Figura 13 – Formação de um sistema fotovoltaico (SFV).	34
Figura 14 – Sistema <i>off-grid</i> , não conectado à rede elétrica.	34
Figura 15 – Sistema <i>on-grid</i> , conectado à rede elétrica.	35
Figura 16 – Circuito elétrico equivalente da célula fotoelétrica.....	35
Figura 17 – Ligação de células em série num painel.	36
Figura 18 – Curvas I-V - diversas temperaturas.....	37
Figura 19 – Curvas I-V - diversas irradiâncias.....	38
Figura 20 – Curvas P-V e I-V combinadas.	38
Figura 21 – Variação da resistência em série.	39
Figura 22 – Variação da resistência de derivação.....	39
Figura 23 – Composição de painéis em série e paralelo.....	40
Figura 24 – Opções de ligação de arranjos de painéis e inversor.....	40
Figura 25 – Degradação por temperatura de célula não uniforme.	41
Figura 26 – Degradação por sujeira e sombreamento	42
Figura 27 – Degradação por danos no material do painel.....	42
Figura 28 – Estrutura da imagem digital.....	45
Figura 29 – Profundidade de cor - RGB.	46
Figura 30 – Aplicação da técnica de OTSU	47
Figura 31 – Exemplo de neurônio matemático ou artificial.....	48
Figura 32 – Redes neurais mono (esq.) e multicamadas (dir.).....	49

Figura 33 – Exemplo de RNA.....	50
Figura 34 – Obtenção de mapa de características numa operação de convolução. .	50
Figura 35 – Exemplo de operação de agrupamento (<i>pooling</i>).	51
Figura 36 – Fluxo para criação do modelo de RNC.	55
Figura 37 – Fluxo para predição com o modelo de RNC gerado.	56
Figura 38 – Disposição do arranjo de painéis e fluxo das correntes elétricas.	59
Figura 39 – Cenário com irradiância e temperatura de célula uniformes.	60
Figura 40 – Cenário de irradiância com sombra, padrão canto esquerdo.....	61
Figura 41 – Cenário de irradiância com sombra, central.....	62
Figura 42 – Cenário de irradiância com sombra, padrão lado direito.....	62
Figura 43 – Cenário de irradiância com sombra, padrão inferior.....	63
Figura 44 – Cenário de irradiância com sombra, padrão formato “L”......	63
Figura 45 – Cenário de irradiância com sombra, padrão quadro.	64
Figura 46 – Cenário de irradiância com sombra, padrão aleatório.....	64
Figura 47 – Cenário de irradiância com sombra, padrão diagonal.....	65
Figura 48 – Cenário de anomalia com curto-circuito em um segmento.	66
Figura 49 – Cenário de anomalia com circuito aberto em um segmento.	67
Figura 50 – Potência assegurada por tempo de vida útil.	68
Figura 51 – Fluxo de geração de uma curva I-V	74
Figura 52 – Fluxo da geração de uma amostra de imagens de curvas I-V.	75
Figura 53 – Exemplo de ficha técnica de painel fotovoltaico EMSB-535M HC.	76
Figura 54 – Limite operacionais de painel fotovoltaico.....	79
Figura 55 – Exemplo de curvas I-V em catálogos de painéis fotovoltaicos.....	80
Figura 56 – Exemplo de curvas I-V em catálogos de painéis fotovoltaicos.....	80
Figura 57 – Curvas equivalentes no cenário de sombras parciais.	88
Figura 58 – Exemplo de parâmetros para treinamento.	89
Figura 59 – Exemplo de evolução do treinamento.	90
Figura 60 – Exemplo de matriz de confusão curvas ROC da base de validação.	90
Figura 61 – Exemplo de parâmetros para predição.	91
Figura 62 – Exemplo de matriz de confusão curvas ROC da base de teste.	91
Figura 63 – Matriz de confusão e Curvas ROC – Treinamento - 8 classes.....	93
Figura 64 – Matriz de confusão e Curvas ROC – Treinamento 12 classes.....	95
Figura 65 – Evolução do treinamento para os modelos com 8 e 12 classes.....	95
Figura 66 – Matriz de confusão e Curvas ROC – Testes - 12 classes.....	96

Figura 67 – Evolução do treinamento com diferentes RNC.	97
Figura 68 – Evolução da predição.....	99
Figura 69 – Evolução total da predição – 12 classes	99
Figura 70 – Comparação da predição por resolução – média de T1 e T2	100
Figura 71 – Matriz de Confusão e Curvas ROC do melhor treinamento.	100
Figura 72 – Matriz de Confusão e Curvas ROC da predição combinada T1/T2.....	101
Figura 73. – Configuração dos parâmetros para geração de uma amostra.	111
Figura 74 – Execução do processamento para um painel.	111
Figura 75 – Execução do processamento para um cenário.	112
Figura 76 – Geração da curva I-V pelo método do diodo único.	112
Figura 77 – Configuração dos parâmetros para geração de uma amostra.	113
Figura 78 – Carga de imagens a partir de um diretório.	113
Figura 79 – Criação da camada convolucional.....	113
Figura 80 – Configuração da regularização durante treinamento.....	114
Figura 81 – Compilação do modelo RNC.	114
Figura 82 – Chamada da rotina de predição.	114
Figura 83 – Carga de parâmetros e imagens para predição.	115
Figura 84 – Carga do melhor modelo para predição.	115
Figura 85 – Gravação de arquivo CSV com indicadores.....	115

LISTA DE TABELAS

Tabela 1 – Resultado de refinamento de pesquisa, foco em “perdas e falhas”	28
Tabela 2 – Resultado de refinamento de pesquisa foco, em “redes neurais”	28
Tabela 3 – Resultado de refinamento de pesquisa na base SCOPUS	29
Tabela 4 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP1	77
Tabela 5 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP2	78
Tabela 6 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP3	78
Tabela 7 – Parâmetros elétricos dos painéis fotovoltaicos – Grupo GP4	79
Tabela 8 – Variação de parâmetros, por painel – Fase 1	82
Tabela 9 – Composição das amostras, por painel, por arranjo – Fase 1	83
Tabela 10 – Parâmetros selecionados para cenários de treinamento – Fase 1	83
Tabela 11 – Variação de parâmetros , por painel – Fase 2	84
Tabela 12 – Composição das amostras, por painel, por arranjo	84
Tabela 13 – Parâmetros selecionados para cenários de treinamento – Fase 2	85
Tabela 14 – Resumo de parâmetros para – 12 classes – Fase 3	85
Tabela 15 – Resumo da segregação de bases – 8 classes	92
Tabela 16 – Resultado do treinamento das amostras – Fase 1	92
Tabela 17 – Resumo da segregação de bases – 12 classes	94
Tabela 18 – Resultado do treinamento das amostras – Fase 2	94
Tabela 19 – Comparação do treinamento – Diferentes arquiteturas RNC	97
Tabela 20 – Resumo da composição final das amostras geradas – 12 classes	98
Tabela 21 – Resultado do treinamento das amostras – Fase 3	98

LISTA DE QUADROS

Quadro 1 – Autores seminais ou relevantes para a pesquisa.	31
Quadro 2 – Exemplo de parâmetros operacionais de um painel solar.	37
Quadro 3 – Arquiteturas de RNC implementadas.	52
Quadro 4 – Curvas I-V normalizadas nas diferentes condições operacionais.	58
Quadro 5 – Curvas I-V geradas com diferentes painéis fotovoltaicos.	70
Quadro 6 – Curvas I-V geradas para irradiâncias diferentes.	71
Quadro 7 – Curvas I-V geradas em temperaturas diferentes.	72
Quadro 8 – Curvas I-V de um painel geradas para diferentes arranjos.	73

LISTA DE ABREVIATURAS E SIGLAS

ABSOLAR	Associação Brasileira de Energia Solar Fotovoltaica.
ANEEL	Agência Nacional de Energia Elétrica.
BMP	BITMAP, ou arquivo de imagem mapeada por bits.
CA	Circuito aberto.
CC	Curto-circuito.
CNN	<i>Convolutional Neural Network</i> .
DL	Deep Learning.
ESG	Environmental, Social and Governance.
IA	Inteligência artificial.
IEEE	<i>The Institute of Electrical and Electronic Engineers</i> , ou Instituto de Engenheiros Elétricos e Eletrônicos.
I-V	Representação do par Corrente e Tensão elétricas de determinado circuito.
ML	<i>Machine Learning</i> ou Aprendizado de Máquina, uma aplicação em IA.
MLP	<i>Multi-Layer Perceptron</i> .
MPPT	<i>Maximum Power Point Tracking</i> ou Rastreamento do Ponto de Máxima Potência.
NREL	<i>National Renewable Energy Laboratory</i> .
NMOT	Condição Normal de Temperatura de Operação de Módulo fotovoltaico.
ODS	Objetivos de Desenvolvimento Sustentáveis da ONU.
ONU	Organização das Nações Unidas.
RNA	Redes neurais artificiais.
RNC	Redes neurais convolucionais.
RNP	Rede Neural Profunda.
ROC	<i>Receiver Operating Characteristic</i> .
SCEE	Sistema de Compensação de Energia Elétrica (SCEE).
SFV	Sistema Fotovoltaico.
JPEG	<i>Joint Photographic Experts Group</i> , ou JPG.
PNG	<i>Portable Network Graphics</i> .

SUMÁRIO

1.	INTRODUÇÃO	17
1.1.	CONTEXTUALIZAÇÃO DO TEMA.....	19
1.1.1.	Importância do estudo de falhas e perdas em SFV.....	19
1.1.2.	Importância das energias renováveis e da eficiência energética ...	20
1.1.3.	Atualidade e importância dos sistemas fotovoltaicos (SFV).....	21
1.2.	PROBLEMA DE PESQUISA	23
1.3.	OBJETIVOS GERAL E ESPECÍFICOS	23
1.4.	JUSTIFICATIVA DA PESQUISA	24
1.5.	DELIMITAÇÃO DO TEMA E LIMITAÇÕES DA PESQUISA	25
2.	REVISÃO DA LITERATURA	27
2.1.1.	PRINCIPAIS AUTORES E TRABALHOS SELECIONADOS	29
3.	FUNDAMENTAÇÃO TEÓRICA	32
3.1.	SISTEMAS FOTOVOLTAICOS	32
3.1.1.	Irradiação solar e princípios da geração de energia fotovoltaica	32
3.1.2.	Formação de um sistema fotovoltaico (SFV).....	33
3.1.3.	Categorias de sistemas fotovoltaico	34
3.1.4.	Modelagem de sistemas fotovoltaicos	35
3.1.5.	Curvas características I-V e P-V.....	37
3.1.6.	Composição de painéis em série e paralelo	40
3.1.7.	Degradação por mismatch	41
3.1.8.	Ferramentas para simulação computacional de um SFV	42
3.2.	MODELAGEM E SIMULAÇÃO.....	44
3.3.	PROCESSAMENTO DE IMAGENS DIGITAIS	44
3.3.1.	Estrutura de uma imagem digital e formatos.....	44
3.3.2.	Operações com imagens digitais	46
3.4.	REDES NEURAIS ARTIFICIAIS E APRENDIZADO DE MÁQUINA	47
3.4.1.	Redes neurais convolucionais (RNC).....	49
3.4.2.	Arquiteturas de RNC implementadas	51
3.4.3.	Métricas para avaliação de desempenho	52
4.	MÉTODO DE PESQUISA	54
4.1.	NATUREZA METODOLÓGICA DA PESQUISA	54
4.2.	METODOLOGIA GERAL DA PESQUISA	55

4.2.1.	Modelo computacional e condições operacionais do SFV.....	57
4.2.1.1.	Arranjo principal dos painéis fotovoltaicos	59
4.2.1.2.	Operação normal.....	60
4.2.1.3.	Operação sob sombras	61
4.2.1.4.	Operação sob curto-circuito (CC).....	65
4.2.1.5.	Operação sob circuito aberto (CA).....	66
4.2.1.6.	Operação sob <i>mismatch</i>	67
4.2.1.7.	Desdobramento da operação sob <i>mismatch</i>	68
4.2.1.8.	Capacidade de predição com o modelo matemático.....	69
4.2.2.	Fluxo da geração de amostras de curvas I-V.....	74
4.2.3.	Parâmetros utilizados na geração das curvas características.....	76
4.2.3.1.	Seleção de painéis fotovoltaicos	76
4.2.3.2.	Seleção de temperaturas	79
4.2.3.3.	Seleção de irradiâncias	80
4.2.4.	Planejamento dos experimentos	81
4.2.4.1.	Fase 1 - Validação do modelo com 8 classes	82
4.2.4.2.	Fase 2 – Validação do modelo com 12 classes	83
4.2.4.3.	Fase 3 – Validação do modelo com melhor resultado.....	85
4.2.5.	Procedimento de execução de um experimento	85
4.3.	PREPARAÇÃO DAS FERRAMENTAS COMPUTACIONAIS	87
4.3.1.	Algoritmo para geração de curvas características I-V.....	87
4.3.2.	Algoritmo para treinamento de RNC	88
4.3.3.	Algoritmo para predição em amostras	91
5.	EXECUÇÃO DOS EXPERIMENTOS	92
5.1.	Fase 1 – Execução do treinamento do modelo com 8 classes	92
5.2.	Fase 2 – Execução do treinamento do modelo com 12 classes	94
5.3.	Fase 3 – Otimização do treinamento do melhor modelo	97
6.	RESULTADOS E DISCUSSÕES.....	99
7.	CONCLUSÕES	102
8.	CONSIDERAÇÕES FINAIS E CONTRIBUIÇÕES DO ESTUDO	103
9.	TRABALHOS FUTUROS E APRIMORAMENTOS	104
	REFERÊNCIAS.....	105
	APÊNDICE A – AMBIENTE COMPUTACIONAL UTILIZADO.....	110
	APÊNDICE B – PROGRAMA PARA GERAÇÃO DE CURVAS I-V	111

APÊNDICE C – PROGRAMA PARA TREINAMENTO DE RNC	113
APÊNDICE D – PROGRAMA DE PREDIÇÃO COM MODELO DE RNC.....	115

1. INTRODUÇÃO

Com o crescente aumento do investimento em instalações geradoras de energia através da energia solar, como exemplo na Figura 1, denominados genericamente de sistemas fotovoltaicos (SFV), cresce a necessidade de monitoramento da performance e do diagnóstico de falhas (HUANG;WAI;GAO, 2019), a fim de evitar perdas econômicas e danos às instalações (KIM *et al.*,2021).

Figura 1: Detalhes de usina fotovoltaica em Minas Gerais.




Fonte: Adaptado de Portal Solar (2024a).

A capacidade de modelar a potência gerada e as consequentes perdas sob diversas condições pode apoiar na identificação de problemas e avaliar se o SFV está operando conforme projetado (STEIN *et al.*, 2016).

Diversas pesquisas buscaram desenvolver modelos, métodos ou ferramentas com diferentes abordagens para apoiar esse desafio. Kim *et al.* (2021) forneceu um método para identificar anomalias em função da taxa de variação da corrente e tensão no SFV. Spataru *et al.* (2015) apresentou uma forma de usar as curvas características I-V, ou apenas curvas I-V, conforme exemplo na Figura 2, que são gráficos obtidos do traçado do comportamento da tensão em função da corrente elétrica gerada ao longo de todo o ciclo operacional do SFV. Em sua pesquisa, obteve os gráficos dos próprios inversores, equipamentos que convertem a corrente contínua gerada em corrente alternada, para interligação do SFV à rede de distribuição de energia elétrica. Complementando, Sarikh *et al.* (2019) apresentou uma solução de monitoramento online, que compara condições previstas e modeladas numa rede neural com as curvas I-V medidas em campo. Huang, Wai e Gao (2019) apresentaram um método

de diagnóstico de falhas através de árvores de decisão, também baseado na obtenção das curvas I-V, introduziram os conceitos de normalização dos dados num cenário de operação padrão para aprimorar o desempenho do algoritmo.

Figura 2: Exemplo de curva I-V sob diversas condições



Fonte: Adaptado de Sarick *et al.* (2019).

A grande maioria destes trabalhos utilizou um SFV instalado em uma empresa, instituição de ensino ou pesquisa, ou simplesmente construiu um sistema em laboratório, limitando os dados coletados e consequentemente, a generalização dos resultados obtidos. Uma possível expansão desses estudos para grande variedade de painéis fotovoltaicos e condições operacionais é complexa e custosa.

Por outro lado, Chen *et al.* (2021) apresentou uma solução utilizando redes neurais baseada no processamento de ampla base de dados de curvas I-V medidas e disponibilizadas pelo NREL (*National Renewable Energy Laboratory*).

Nestas condições, essa pesquisa desenvolveu como alternativa uma ferramenta para gerar as curvas I-V a partir do modelo matemático do circuito equivalente de um SFV, operando em condições normais ou sob anomalias. Essas curvas alimentaram um modelo de rede neural convolucional (RNC), capaz de identificar as diversas condições operacionais simuladas a partir das curvas características.

Desta forma, este trabalho buscou aprimorar os trabalhos já existentes,

principalmente através da generalização do seu uso para diferentes modelos de painéis fotovoltaicos, arranjos em série e paralelo, faixa de temperaturas e irradiancias, bem como oferecendo uma base de imagens e um modelo treinado para estudos futuros.

1.1. CONTEXTUALIZAÇÃO DO TEMA

1.1.1. Importância do estudo de falhas e perdas em SFV

A produção de energia solar ao longo do dia depende da incidência da irradiação solar nos painéis fotovoltaicos, temperatura e umidade (STEIN *et al.*, 2016; KIM *et al.*, 2021). Também é influenciada pela localização geográfica (latitude), técnicas de montagem, horário do dia e período do ano (HAY; DAVIES, 1980; PEREZ, 1987).

Outros fatores também podem influenciar temporariamente a produção, como: barreiras físicas (chaminés, torres, edificações, árvores, etc.), nuvens e condições climáticas, além de depósito de impurezas causados por pássaros e pelo vento ou a deterioração dos equipamentos com a idade (BONTHAGORLA; MIKKIL, 2020).

Segundo Chein (2017), como os SFV operam em ambiente externo severo, sem controle sobre esses fatores, possuem a tendência de sofrer várias falhas restando o monitoramento de eventuais perdas na geração de energia para a devida interpretação da causa, sempre dependente de avaliação humana. Falhas recorrentes nos SFV ainda podem afetar seu rendimento, aumentar os custos de manutenção e reduzir sua vida útil (SARIKH *et al.*, 2019).

Uma alternativa para avaliação da condição operacional do SFV é a extração de uma curva característica de corrente x tensão (curva I-V) ou potência x tensão (curva P-V), com posterior comparação com valores esperados e avaliação da causa de eventuais anomalias, como também indicado por Spataru *et al.* (2015) e Huang, Wai e Gao (2019).

Alguns fatores que afetam o formato das curvas características são: o curto-circuito ou circuito aberto no painel fotovoltaico, a degradação por impacto ou idade, a variação entre os parâmetros elétricos (tolerância) dos diversos painéis conectados em série ou paralelo, entre outros (CHEN *et al.*, 2017).


Outro fator que altera o formato das curvas características e afeta consideravelmente a produção de energia é a presença de sombreamento parcial que

reduz a irradiação sobre parte do SFV, podendo causar aquecimento e dano aos equipamentos, se não estiverem com seus mecanismos de proteção em devido funcionamento, como os diodos de *by-pass* (BONTHAGORLA; MIKKIL, 2020).

O principal impacto da variação da curva característica está na ocorrência de mais de um ponto de máxima potência, ocasionado por ondulações na curva e que afetará o desempenho do mecanismo de maximização da potência de saída (MPPT) disponível nos inversores do SFV, que procuram regular o valor da tensão e da corrente elétrica de saída de forma a maximizar a potência e o rendimento do sistema. Nestas condições, além das perdas já citadas, o SFV poderá operar numa condição abaixo de sua capacidade, resultando também em perdas devido ao mecanismo MPPT (STEIN, 2012).

A Figura 3 mostra um conjunto de painéis em série com diferentes características e ligadas a um inversor com módulo MPPT. O resultado final desse sistema será no máximo quatro vezes o valor da menor potência, limitado à menor tensão e menor corrente gerada nos painéis.

Figura 3: Ligação de painéis num inversor com MMT



Fonte: Adaptado de Souza (2019)

1.1.2. Importância das energias renováveis e da eficiência energética

Alterações nas condições climáticas, como o aquecimento global, afetam a qualidade de vida de toda a população mundial e têm forte impacto na economia. A redução da emissão de carbono passa, entre outras possibilidades, pela substituição de fontes de energia poluidoras por energias renováveis e sustentáveis.

Atualmente observa-se forte interesse no mercado de capitais nas práticas de sustentabilidade ambiental, social e de governança corporativa (ESG).

Essas práticas estão fortemente alinhadas aos Objetivos Desenvolvimento Sustentáveis (ODS) propostos pelo Pacto Global da ONU, na iniciativa chamada

Agenda 2030 (ASSEMBLEIA GERAL, 2015) e, segundo a consultoria Ernest Young, são essenciais para a tomada de decisões dos investidores (PACTO GLOBAL REDE BRASIL, 2022).


Resumidamente, o ODS número 7 propõe, até 2030, assegurar o acesso universal, a serviços de energia, aumentar a participação de energias renováveis na matriz energética global e melhorar a eficiência energética.

1.1.3. Atualidade e importância dos sistemas fotovoltaicos (SFV)

Em 17 de abril de 2012 a Agência Nacional de Energia Elétrica (ANEEL) publicou a Resolução 482 (ANEEL, 2012), que definiu as regras do segmento de geração distribuída, posteriormente alterada pela Resolução 687 (ANEEL, 2015). Pessoas físicas ou jurídicas foram autorizadas a instalar micro geradores (até 75 kW) ou minigeradores (entre 75 kW e 5 MW) para produção de energia elétrica para atendimento da demanda das unidades consumidoras.

O marco mais importante foi a criação do Sistema de Compensação de Energia Elétrica (SCEE), onde a energia produzida é injetada na rede de distribuição local e o consumidor recebe um crédito para abater do consumo de energia de um ou mais imóveis de sua titularidade.


Segundo a Associação Brasileira de Energia Solar Fotovoltaica (ABSOLAR), a energia solar é de fácil instalação e pode reduzir os gastos dos consumidores em até 90%. Permite diversificar o suprimento de energia elétrica apesar de ser uma fonte intermitente. A Figura 4 mostra a geração distribuída no Brasil.



Fonte: Adaptado de ABSOLAR (2023)

Além da utilização da energia solar em sistemas distribuídos, destacam-se também as usinas fotovoltaicas, sistemas centralizados de maior potência já existentes em 23 estados. A combinação da capacidade de geração de ambos os sistemas pode ser vista na Figura 5.

Figura 5: Geração fotovoltaica total e matriz elétrica brasileira



Fonte: Adaptado de ABSOLAR (2023)

Até novembro de 2023, o resumo da matriz elétrica brasileira (ABSOLAR, 2024) mostrava que essas usinas centralizadas atingiram um total de 10,7 GW de potência instalada, contra 24,9 GW da geração distribuída. Porém, segundo a ANEEL (2024), detalhado na Figura 6, existem mais 7,2 GW de potência instalada nas usinas fotovoltaicas centralizadas em construção. Comparando com as usinas eólicas – onde as turbinas e geradores são movimentados pela força dos ventos - essas já atingiram uma potência instalada de 27,6 GW, para um total outorgado de 55,5 GW e devem ser, em breve, superadas.

Figura 6: Potência outorgada por fonte de geração Total / Em construção.

Tipo	Quantidade	Potência Outorgada (kW)	Tipo	Quantidade	Potência Outorgada (kW)
CGH	695	878.883,26	CGH	4	11.000,00
EOL	1647	55.541.791,86	EOL	99	4.167.900,00
PCH	532	7.222.043,22	PCH	27	343.929,00
UFV	21228	144.678.206,37	UFV	183	7.453.846,07
UHE	221	103.580.021,00	UHE	1	49.998,00
UTE	3126	56.201.061,91	UTE	38	4.261.447,00
UTN	3	3.340.000,00	UTN	1	1.350.000,00
Total	27452	371.442.007,62	Total	353	17.638.120,07

CGH	Central Geradora Hidroelétrica (< 1MW)
EOL	Usinas Eólicas
PCH	Pequenas Centrais Hidroelétricas (1,1 MW até 30 MW)
UFV	Usinas Fotovoltaicas
UHE	Usinas Hidroelétricas (> 30 MW)
UTE	Usinas Térmicas
UTN	Usinas Nucleares

Fonte: Adaptado de ANEEL (2024).

Somando toda a capacidade fotovoltaica instalada ou em construção, com os projetos outorgados e ainda não iniciados, a potência total futura pode chegar a 144 GW, superando todas as fontes hidroelétricas do país, que giram em torno de 111 GW, somando os diversos tipos de geração conforme detalhes na Figura 6 e praticamente não possuem mais projetos relevantes em construção.

1.2. PROBLEMA DE PESQUISA

Nas condições apresentadas, o trabalho foi direcionado para estender estudos existentes a fim de solucionar a seguinte questão de pesquisa: “Qual modelo computacional, baseado em RNC, poderia ser capaz de identificar as condições operacionais de um SFV operando sob diferentes faixas de temperaturas, irradiâncias e arranjos de painéis fotovoltaicos?”

1.3. OBJETIVOS GERAL E ESPECÍFICOS

O objetivo principal desse trabalho é desenvolver um modelo computacional utilizando redes neurais convolucionais (RNC) para identificação e classificação de condições anormais de operação de arranjos de painéis fotovoltaicos, através de suas curvas I-V.

Como objetivos específicos, destacam-se:


- a) Construir um gerador de curvas características I-V que permita a simulação de arranjos de painéis fotovoltaicos de diferentes características, operando em diferentes condições de irradiância e temperaturas, além de condições de falha como curto-circuito e circuito aberto em painéis fotovoltaicos; e perdas como mismatch e sombreamento;
- b) Gerar e validar uma base de imagens digitais de curvas características I-V normalizadas, de diversos arranjos de painéis fotovoltaicos, operando sob diversas irradiâncias e temperaturas, em diversas condições operacionais, para fomentar novos estudos;
- c) Treinar e validar um modelo de RNC para predição das condições operacionais de SFV, com capacidade de generalização, utilizando a base de imagens gerada e validada.

1.4. JUSTIFICATIVA DA PESQUISA

A partir da identificação do problema de pesquisa a ser explorado e solucionado e em função da revisão da literatura e da fundamentação teórica, decidiu-se dar continuidade ao trabalho em função das seguintes justificativas:

- a) Relevância do tema no contexto atual da produção de energia elétrica (ANEEL, 2024), no uso de fontes renováveis e na busca por eficiência energética (ASSEMBLEIA GERAL DA ONU, 2015).
- b) Importância de predição de perdas e falhas visando maximização da energia elétrica produzida, redução da deterioração e aumento de vida útil dos equipamentos e consequentemente, maior segurança e redução de custos (Chen *et al.*, 2017; Sarikh *et al.*, 2019)
- c) Uso crescente de sistemas digitais para simulação do comportamento de sistemas físicos, em função das dificuldades técnicas e custos envolvidos na construção e operação de laboratórios para testes, como observados em Huang; Wai e Gao (2019), Bonthagorla e Mikkil (2020), entre outros.
- d) Relevância científica, contemporaneidade e crescente interesse pelo tema abordado, incluindo o uso de redes neurais para a análise e detecção de falhas e perdas em SFV, conforme pode se comprovar nas Figura 7 com o resultado da pesquisa de artigos científicos relacionados ao tema proposto, sendo o primeiro com a evolução dos artigos relevantes que utilizem redes neurais na análise de perdas e falhas em sistemas fotovoltaicos e o segundo, com a refinamento de redes neurais convolucionais (RNC). Maiores detalhes no Capítulo 2.

Figura 7 – Evolução de artigos relacionados ao tema.



Fonte: Extraído de ELSEVIER (2024).

1.5. DELIMITAÇÃO DO TEMA E LIMITAÇÕES DA PESQUISA

Para se estudar as condições operacionais de um arranjo de painéis fotovoltaicos, além da disponibilidade dos equipamentos, seriam necessários um amplo espaço para sua instalação, equipamentos para variação da irradiância solar e temperatura ambiente e medição do comportamento elétrica dos circuitos. Havendo necessidade de estudar diversas composições de arranjos, acrescenta-se o esforço e tempo para reconexão dos painéis fotovoltaicos e, por fim, amplos recursos financeiros para viabilizar todo o trabalho. Laboratório físicos são caros, ao contrário de laboratórios ou ferramentas virtuais, que ainda permitem acesso quase ilimitado e oferecem a oportunidade de repetição de experimentos (CASALS-TORRENS, 2013).

Nestas condições, todo o trabalho se limitou ao uso de modelagem e simulações por meio de ferramentas computacionais, aproveitando-se da grande disponibilidade de disponibilidade de modelos matemáticos (STEIN, 2012) e de ferramentas computacionais que representam os sistemas reais (GURUPIRA; RIX, 2017; HOLMGREN; HANSEN; MIKOFSKI, 2018; HOLMGREN *et al.*, 2015).

Acerca da utilização da energia elétrica produzida pelos SFV, não foram avaliados detalhes da legislação, limites ou regras de compensação, custos de implantação ou manutenção, nem mesmo as vantagens ou desvantagens em relação a outras fontes renováveis, pois esses temas não estão alinhados com os objetivos propostos.

Decidiu-se estudar as condições operacionais do circuito do SFV que opera em corrente contínua, ou seja, os painéis fotovoltaicos que são as fontes geradoras de energia e suas interconexões, até a entrada do equipamento inversor, que transforma a energia em corrente alternada.

O comportamento do SFV em corrente alternada não foi incluído neste trabalho, pois demanda outros modelos matemáticos e apresenta características próprias para interpretação de perdas e falhas, constituindo-se assim em outro escopo de estudo, também amplamente presente nas pesquisas acadêmicas.

Também decidiu-se estudar apenas o arranjo em série e paralelo dos painéis fotovoltaicos, pois é o modelo mais utilizado na prática, apesar de ampla pesquisa científica que busca minimizar o impacto de falhas e do sombreamento nos painéis fotovoltaicos através de diferentes formas de conexão.

Para essa pesquisa, analisou-se apenas a relação causa-efeito para um painel fotovoltaico inteiro (totalidade de suas células em condição normal, sombreamento, curto-circuito ou circuito aberto). Desta forma, não foram analisadas condições de falha em diodos de by-pass inseridos pelos fabricantes nos próprios painéis, pois o efeito da falha desses componentes num arranjo com dezenas de painéis interconectados em série-paralelo, é muito pequeno, não permitindo a identificação precisa da relação causa-efeito, gerando falsos positivos ou negativos em relação a outras classes, como um curto-circuito ou sombreamento parcial.

A inclusão de componentes de proteção nos arranjos como os diodos de bloqueio também não foi analisada, bem como os efeitos de *mismatch* devido a operação de arranjos heterogêneos, em função de eventual substituição de peças devido manutenção ou ampliação da instalação geradora de energia elétrica fotovoltaica.

2. REVISÃO DA LITERATURA

A fim de se levantar a produção científica relacionada ao tema e objetivos propostos, identificar eventuais tendências ou oportunidades de aprimoramento, além de avaliar a relevância acadêmica dos tópicos que fazem parte desta pesquisa, foi realizada uma revisão na literatura e a busca de trabalhos correlatos.

A partir dos primeiros artigos científicos obtidos e que despertaram o interesse inicial em tópicos relacionados ao tema, fez-se uma busca inicial, acessando parte das referências bibliográficas citadas, repetindo tal procedimento sucessivamente até identificar um artigo seminal ou de grande relevância;

Inicialmente, buscou-se identificar no título, palavras chaves e resumo, alguma ligação com os tópicos em análise. Sempre que possível, procurou-se identificar se o trabalho se baseou em número significativo de referências e principalmente, se foi citado em outros trabalhos acadêmicos, selecionando preferencialmente aqueles com dezenas ou centenas de citações.

Também foram considerados como critérios a contemporaneidade (últimos 10 anos) e se foram publicados em periódicos de fontes renomadas como ELSEVIER, SPRINGER, WILEY ou em congressos de instituições relevantes ligadas à engenharia, como IEEE.

Uma vez identificados pontos relevantes que conectavam os trabalhos, necessidade de maior esclarecimento ou aprofundamento sobre algum tópico, partiu-se para uma busca de maior volume de trabalhos relacionados, através de plataformas *online*, como o Portal da CAPES¹ e a ferramenta SCOPUS². Essas plataformas contemplam dezenas de bases indexadas com dissertações, periódicos, livros ou artigos, permitindo aplicar filtros por período e tipo da publicação, idioma, entre outros. Basicamente foram avaliados artigos científicos de maior relevância nos idiomas português e inglês.

A Tabela 1 mostra as palavras-chave utilizadas na primeira pesquisa no Portal da CAPES, como foram combinadas e o total de artigos identificados em cada base. Procurou-se identificar trabalhos de maior relevância (CAPES, 2019), associados com

¹ Acesso à plataforma online conforme CAPES (2023).

² Acesso à plataforma online a partir do Portal da CAPES, conforme Elsevier (2024).

a geração de energia elétrica através da energia solar e que abordavam a análise ou diagnóstico de perdas ou falhas, utilizando-se expressões similares, identificadas através da leitura dos primeiros artigos.

Tabela 1 – Resultado de refinamento de pesquisa, foco em “perdas e falhas”.

Expressão de Pesquisa	Base	Resultados
“solar energy” OU “photovoltaic” OU “PV system”	Web of Science (<i>Science Citation</i>)	109.171
	Science Direct Journals (Elsevier)	82.596
	Wiley Online Library	31.070
	Springer Link	19.216
	IEEE <i>Eletronic Library</i>	12.421
“solar energy” OU “photovoltaic” OU “PV system” E “fault” OU “losses” OU “mismatch”	Web of Science (<i>Science Citation</i>)	11.500
	Science Direct Journals (Elsevier)	8.306
	Wiley Online Library	1.565
	Springer Link	1.391
	IEEE <i>Eletronic Library</i>	2.697
“solar energy” OU “photovoltaic” OU “PV system” E “fault” OU “losses” OU “mismatch” E “diagnosis” OU “diagnostic” OU “analysis” OU “detection” OU “estimation” OU “simulation”	Web of Science (<i>Science Citation</i>)	6.744
	<i>Science Direct Journals</i> (Elsevier)	5.419
	Wiley Online Library	665
	Springer Nature Complete Journals	857
	IEEE <i>Eletronic Library</i>	1.858

Fonte: Elaborado pelo autor.

Na sequência, refinou-se a pesquisa, conforme mostrado na Tabela 2, acrescentando trabalhos associados a redes neurais e, posteriormente, redes neurais convolucionais (RNC).

Tabela 2 – Resultado de refinamento de pesquisa foco, em “redes neurais”

Expressão de Pesquisa	Base	Resultados
("solar energy" OU "photovoltaic" OU "PV system") E ("fault" OU "losses" OU "mismatch") E ("diagnosis" OU "diagnostic" OU "analysis" OU "detection" OU "estimation" OU "simulation") E ("machine learning" OU "deep learning" OU "neural network")	Web of Science (<i>Science Citation</i>)	279
	<i>Science Direct Journals</i> (Elsevier)	254
	Wiley Online Library	50
	SpringerLink	41
	IEEE <i>Eletronic Library</i>	145
("solar energy" OU "photovoltaic" OU "PV system") E ("fault" OU "losses" OU "mismatch") E ("diagnosis" OU "diagnostic" OU "analysis" OU "detection" OU "estimation" OU "simulation") E ("machine learning" OU "deep learning" OU "neural network") E ("convolutional" OU "CNN")	Web of Science (<i>Science Citation</i>)	33
	<i>Science Direct Journals</i> (Elsevier)	51
	Wiley Online Library	5
	IEEE <i>Eletronic Library</i>	26

Fonte: Elaborado pelo autor.

Por fim, a pesquisa mais refinada foi repetida na ferramenta SCOPUS, que oferece melhores recursos para identificação da relevância dos trabalhos, autores e fontes de publicação. As expressões e resultados estão listados na Tabela 3.

Os artigos foram ordenados por relevância ou por número de citações e tiveram seu título e resumo analisados. A relevância na plataforma SCOPUS é calculada a partir de um conjunto de fatores, entre eles: a proximidade das expressões pesquisadas, a presença delas em partes mais importantes do texto, como título e resumo, o número de vezes que aparecem, etc. (ELSEVIER, 2023a). Os principais documentos foram selecionados e carregados na íntegra para leitura e avaliação posterior.

Tabela 3 – Resultado de refinamento de pesquisa na base SCOPUS

Expressão de Pesquisa	Base	Resultados
"solar energy" OU "photovoltaic" OU "PV system" E "fault" OU "losses" OU "mismatch" E "diagnosis" OU "diagnostic" OU "analysis" OU "detection" OU "estimation" OU "simulation" E "machine learning" OU "deep learning" OU "neural network"	SCOPUS (Elsevier)	576
"solar energy" OU "photovoltaic" OU "PV system" E "fault" OU "losses" OU "mismatch" E "diagnosis" OU "diagnostic" OU "analysis" OU "detection" OU "estimation" OU "simulation" E "machine learning" OU "deep learning" OU "neural network" E "convolutional" OU "CNN"	SCOPUS (Elsevier)	74

Fonte: Elaborado pelo autor.


2.1.1. PRINCIPAIS AUTORES E TRABALHOS SELECIONADOS

Durante a revisão da literatura, identificou-se um conjunto de autores relevantes e a partir dos mesmos se teve acesso a autores de trabalhos seminais.

Também foram identificados os que mais publicaram trabalhos nos últimos 10 anos, relacionados aos tópicos da pesquisa realizada:


- Conforme mostrado na Figura 8, com trabalhos que abordam o uso de redes neurais em análise ou diagnóstico de perdas e falhas em SFV e,
- Conforme Figura 9, para aqueles que abordam o uso específico de RNC.

Figura 8 – Principais autores entre 2013-2023: análise de perdas e falhas.



Fonte: Extraído de ELSEVIER (2024).

Figura 9 – Principais autores entre 2013-2023: perdas e falhas usando RNC.




Fonte: Extraído de ELSEVIER (2024).

Dentre os autores listados nas Figuras 8 e 9, Chen, Z. e Gao W., tiveram artigos efetivamente avaliados e que contribuíram com essa pesquisa.

Através do um indicador de impacto, CiteScore (ELSEVIER, 2023b), a plataforma SCOPUS calcula quantas vezes um artigo é citado em relação a todos os artigos publicados nas respectivas fontes, considerando os últimos 4 anos, permitindo comparar a relevância entre as fontes ao longo do tempo.

Na Figura 10 é possível observar um crescimento nas citações para os artigos selecionados na pesquisa, confirmando novamente um aumento de interesse no tema proposto.

Figura 10 – Distribuição das citações (CiteScore) de acordo com a fonte.



Fonte: Extraído de ELSEVIER (2024).

No Quadro 1 são destacados os principais autores para os tópicos mais relevantes do trabalho, incluindo alguns seminais, seja na fundamentação teórica ou como referência em métodos, ferramentas ou abordagens utilizadas nas diversas fases do trabalho de pesquisa.

Quadro 1 – Autores seminais ou relevantes para a pesquisa.

Tópicos	Assunto	Autores
Modelagem de SFV	Irradiação solar	HAY; DAVIES (1980), PEREZ (1987) LOUTZENHISER <i>et al.</i> (2007)
	Circuito elétrico equivalente do diodo único	BISHOP (1988), TIAN <i>et al.</i> (2012). SOTO; KLEIN; BECKMAN (2006)
	Variação de parâmetros com temperatura e irradiância	STEIN (2012) TIAN <i>et al.</i> (2012).
	PVLIB	HOLMGREN <i>et al.</i> , (2015, 2018) HOLMGREN; HANSEN; MIKOFSKI (2018)
Falhas e perdas em SFV	Arranjos e sombreamento parcial Mismatch, Uso de RNA	Bonthagorla e Mikkili (2020) CHEN <i>et al.</i> (2017), CHEN <i>et al.</i> (2021)
Redes Neurais	Fundamentação Teórica	MCCULLOCH e PITTS (1943) MITCHELL (1997) GOODFELLOW; BENGIO; COURVILLE (2016)
Arquiteturas de RNC	LENET-5	LeCun <i>et al.</i> (1989, 1998)
	ALEXNET	Krizhevsky, Sutskever e Hilton (2017)
	VGG16	Simonyan e Zisserman (2015)
	EfficientNET_V2S	Tan e Le (2021)
Imagem digital	Processamento de imagens	GONZALEZ e WOODS (2010) KLETTLE (2014)
Metodologia científica	Metodologia e Revisão de Literatura	MARCONI; LAKATOS (2021) CRESWELL (2021), GIL (2002)

Fonte: Elaborado pelo autor.

3. FUNDAMENTAÇÃO TEÓRICA

3.1. SISTEMAS FOTOVOLTAICOS


3.1.1. Irradiação solar e princípios da geração de energia fotovoltaica

A irradiação solar depende de diversos fatores: condições atmosféricas (nebulosidade, umidade relativa do ar etc.), a disponibilidade de radiação solar, a posição no tempo (hora do dia e época do ano) e a latitude local.

A irradiação solar ocorre em todas as direções e pode chegar à superfície de três formas, conforme Figura 11.

- a) Direta (G_n): Chega à superfície da terra sem mudar de direção;
- b) Difusa (G_{dif}): Chega à superfície sem uma direção definida, após ter sido dispersada pelas moléculas e partículas presentes na atmosfera;
- c) Refletida (albedo): Chega à superfície e foi previamente refletida pelo solo ou superfícies adjacentes, verticais ou horizontais.

Figura 11 – Irradiação solar e ângulos relevantes.



Fonte: Adaptado de PEREIRA (2017).

Por estar localizado próximo à linha do Equador, o Brasil recebe alta incidência de sol durante todo o dia. Segundo o Atlas Brasileiro de Energia Solar (PEREIRA, 2017), o país recebe, durante todo o ano, mais de 3 mil horas de brilho do sol, correspondendo a uma incidência solar diária que entre 4.500 a 6.300 (Wh/m²), com pouca variação ao longo das estações do ano.

O ciclo anual impacta na geração solar devido à proximidade do sol: no inverno, com os dias mais curtos, temos uma geração reduzida; e no verão, com os dias mais longos, temos uma geração ampliada.

Em relação ao ciclo diário, a irradiância solar atinge seu valor máximo 1.000 [W/m²] às 12 [h], momento do dia em que o Sol está na posição mais elevada de modo que a radiação solar percorre a menor trajetória na atmosfera, em condições de céu claro.

Para o desenvolvimento da pesquisa foi considerada a irradiância total no momento da análise de um cenário operacional. Sua aplicação se baseia nos trabalhos em de LOUTZENHISER *et al.* (2007), Hay e Davies (1980) e Perez (1987) e estão incorporados na ferramenta computacional utilizada, a PVLIB, desenvolvida por Holmgren, Hansen e Mikofski (2018); Holmgren *et al.* (2015).

3.1.2. Formação de um sistema fotovoltaico (SFV)

A energia elétrica é produzida através de uma célula fotovoltaica, fabricada com silício ou uma combinação de materiais, que recebe a irradiação do sol e gera uma corrente e tensão elétrica contínua. A célula é combinada com outras em série, empacotadas num invólucro de alumínio e vidro, chamado painel fotovoltaico. A Figura 12 mostra painéis fabricados com os materiais mais comuns na atualidade.


Figura 12 – Exemplo de painéis: mono e policristalino.



Fonte: Adaptado de Portal Solar (2024c).

Os painéis podem ser organizados (conectados) em série e paralelo, formando os arranjos, que por sua vez formam as usinas ou fazendas fotovoltaicas, conhecidos com sistemas fotovoltaicos (SFV), conforme Figura 13.

Figura 13 – Formação de um sistema fotovoltaico (SFV).




Fonte: Adaptado de Portal Solar (2024b).

3.1.3. Categorias de sistemas fotovoltaico

Os SFV podem ser classificados de forma simplificada em:

- a) Sistema *off-grid*: Conforme mostrado na Figura 14, é um sistema desconectado da rede de distribuição de energia elétrica e a energia produzida fica armazenada em baterias. Muito usado em locais remotos ou em veículos.

Figura 14 – Sistema *off-grid*, não conectado à rede elétrica.




Fonte: Adaptado de Moraes (2024).

- b) Sistema *on-grid*: Conforme mostrado na Figura 15, é um sistema conectado na rede de distribuição de energia elétrica e a energia produzida é

transferida para a mesma, permitindo que o excedente de consumo seja compensação na conta de energia elétrica do consumidor. Por esse motivo, esta pesquisa se concentrou apenas nesta categoria de SFV.

Figura 15 – Sistema *on-grid*, conectado à rede elétrica.




Fonte: Adaptado de Moraes (2024).

- c) Sistema híbrido: combina os dois sistemas anteriores, mantendo a conexão com a rede de distribuição de energia elétrica em conjunto com um banco de baterias para suprir eventuais interrupções no fornecimento nos horários em que o SFV não estiver produzindo energia elétrica.

3.1.4. Modelagem de sistemas fotovoltaicos

Um modelo de circuito elétrico equivalente para uma célula fotovoltaica, corresponde a uma função contínua I-V (corrente-tensão) para um conjunto de parâmetros de entrada estabelecidos, relacionados com suas características construtivas. Um modelo amplamente utilizado e implementado nas bibliotecas PVLIB PYTHON e PV_LIB MATLAB é o modelo de único diodo, apresentado de forma simplificada na Figura 16.


Figura 16 – Circuito elétrico equivalente da célula fotoelétrica.



Fonte: Extraído de Hansen (2015).

Num painel solar ou painel fotovoltaico, as células são normalmente combinadas em série, conforme a Figura 17, de forma que todo o painel também passa a ser representado por um circuito equivalente como se ele fosse uma grande célula.

Figura 17 – Ligação de células em série num painel.



Fonte: Extraído de Honsberg e Bowden (2019).

A relação entre a corrente e a tensão de saída do circuito equivalente pode ser observada na equação (1).

$$I_a = N_p I_{rr} - N_p I_o \left[\exp \left(\frac{q \left(V_a + I_a \frac{N_s}{N_{sh}} R_s \right)}{N_s n k T_c} \right) - 1 \right] - \frac{V_a + \frac{I_a N_s R_s}{N_{sh}}}{\frac{N_s R_{sh}}{N_p}} \quad (1)$$

Sendo I_a a corrente de saída da célula ou arranjo; V_a é a tensão de saída da célula ou arranjo; N_s é o número de células em série no painel; N_p é o número de células em paralelo no painel; I_{rr} é a corrente gerada pelo processo fotovoltaico a partir de uma irradiância de referência; I_o é a corrente de saturação da célula fotovoltaica; n é fator que aponta o quanto que o diodo está de acordo com o modelo proposto; q é constante carga elementar ($1,60218 \times 10^{-19}$ [C]); k é a constante de Boltzmann ($1,38066 \times 10^{-23}$ [J/K]); T_c é a Temperatura da célula; R_s é a resistência em série e R_{sh} é a resistência de derivação.

Os parâmetros n , R_s e R_{sh} dependem das características físicas dos sistemas fotovoltaicos (material, construção, etc.) e precisam ser fornecidos.

Os equipamentos operam sob diversas condições, mas os fabricantes costumam fornecer parâmetros para apenas um cenário.

Através do método proposto por Soto, Klein e Beckman (2006), é possível calcular os parâmetros necessários para a solução da equação (1) do modelo do único diodo utilizando apenas dados fornecidos pelos fabricantes. No artigo foram citadas as simplificações, uma comparação com outro método de estimativa dos parâmetros,

além de dados medidos num experimento, demonstrando os bons resultados que podem ser obtidos. Esse método está disponível na biblioteca PVLIB PYTHON e foi escolhido para uso.

No Quadro 2 são listados os parâmetros em geral fornecidos pelos fabricantes e um exemplo de valores para um painel solar específico.


Quadro 2 – Exemplo de parâmetros operacionais de um painel solar.

Parâmetro	Unidade	Valor	Descrição
I_{sc}	A	6,62	Corrente de curto-circuito (sem carga terminais fechados)
V_{oc}	V	33,80	Tensão de saída (sem carga terminais em aberto)
I_{mp}	A	6,06	Corrente no ponto de máxima potência
V_{mp}	V	26,00	Tensão no ponto de máxima potência
aT	mA/°C	5,50	Coefficiente de ajuste da corrente em função da temperatura
bT	mV/°C	-120	Coefficiente de ajuste da tensão em função da temperatura

Fonte: Elaborado pelo autor, baseado em BISOL (2022).

3.1.5. Curvas características I-V e P-V


Os parâmetros do circuito equivalente são calculados a partir de um cenário operacional específico ou de referência. Uma vez estabelecidos e substituídos na equação (1), é possível traçar as curvas I-V e para as demais condições operacionais, incluindo a variação da temperatura da célula (°C) na Figura 18 e da irradiância (em W/m^2), na Figura 19.



Fonte: Adaptado de TIAN *et al.* (2012).

Para o cálculo, uma prática referenciada na literatura é o uso da função W de Lambert para solucionar a equação (1) do modelo do diodo único com excelentes resultados (JAIN, 2004). Esse método está disponível na biblioteca PVLIB PYTHON e foi selecionado para uso.

Figura 19 – Curvas I-V - diversas irradiâncias.




Fonte: Adaptado de TIAN *et al.* (2012).

Em relação à potência, a mesma pode ser obtida pela equação (2) e seu comportamento visto em detalhes na Figura 20.

$$P = I_a V_a \quad (2)$$

Sendo V_a é a tensão combinada de saída do arranjo; e, I_a é a corrente de saída.


Figura 20 – Curvas P-V e I-V combinadas.



Fonte: Adaptado de TIAN *et al.* (2012).


Diferenças nas características construtivas resultarão em R_s e R_{sh} diferentes. Uma comparação das curvas I-V (Figura 21 e Figura 22) a partir de valores fornecidos por diversos fabricantes, poderá mostrar diferença no desempenho dos sistemas fotovoltaicos, afetando o ponto de máxima potência e as perdas no sistema.

Figura 21 – Variação da resistência em série.



Fonte: Adaptado de Soto, Klein e Beckman (2006).

Figura 22 – Variação da resistência de derivação.




Fonte: Adaptado de Soto, Klein e Beckman (2006).

3.1.6. Composição de painéis em série e paralelo


No mundo real um painel fotovoltaico gera uma corrente e tensão elétrica inferiores aos necessários para conectá-lo diretamente num inversor e na rede elétrica de distribuição. Por isso, são agrupados em série, formando um segmento ou string que mantém a corrente constante e soma as tensões elétricas; bem como vários segmentos são agrupados em paralelo, mantendo a tensão constante e somando as correntes elétricas de cada segmento, conforme exemplo da Figura 23. Desta forma, um ou mais arranjos de painéis fotovoltaicos podem ser interligados a um equipamento inversor que fará a conversão da corrente e tensão elétricas contínuas para alternada, conforme a Figura 24.

Figura 23 – Composição de painéis em série e paralelo.



Fonte: Adaptado de MPPT SOLAR (2024).

Figura 24 – Opções de ligação de arranjos de painéis e inversor.



Fonte: Adaptado de Moraes (2024).


Independente da disposição e da quantidade de painéis envolvidos, o ponto em que se pode coletar os dados para gerar a curva característica I-V do circuito equivalente de todo o arranjo, será sempre a entrada do módulo inversor, em corrente contínua.

Os SFV de grande porte possuem dezenas de grupos de arranjos de painéis e de inversores interconectados em paralelo, porém, cada grupo precisa ter sua curva I-V analisada separadamente, pois, uma vez convertida para corrente alternada e conectada à rede elétrica, as informações referentes às deformações que as condições operacionais podem causar nas curvas I-V serão perdidas e uma nova análise do comportamento da corrente elétrica e tensão de saída do inversor precisaria ser realizada, o que não fez parte do escopo dessa pesquisa.

3.1.7. Degradação por mismatch

Os painéis fotovoltaicos possuem uma tolerância na sua potência máxima, bem como em sua temperatura operacional, em função da variação dos parâmetros elétricos causada pelos métodos e materiais de fabricação. Consequentemente, essa tolerância se reflete nos valores de corrente máxima de curto-circuito, tensão a vazio, corrente e tensão para o ponto de maior potência. A Figura 25 mostra o efeito que essas diferenças podem causar na temperatura operacional de cada célula.

Figura 25 – Degradação por temperatura de célula não uniforme.



Fonte: Adaptado de ENERGES (2022).

Além disso esses parâmetros sofrem ligeira degradação com o tempo de vida útil ou idade do equipamento, com a presença de sujeira, ou em função de pequenos defeitos ou trincas que vão aparecendo no material que constitui o painel, seja por manuseio, aquecimento ou impacto de objetos.

As Figuras 26 e 27 mostram diversos efeitos intrínsecos aos painéis ou


externos, que podem gerar diferenças entre as condições elétricas previstas pelos fabricantes e as que realmente estarão presentes na operação dos painéis.

Figura 26 – Degradação por sujeira e sombreamento



Fonte: Adaptado de Souza (2019).

Figura 27 – Degradação por danos no material do painel.



Fonte: Adaptado de ENERGES (2022).

3.1.8. Ferramentas para simulação computacional de um SFV

Para o desenvolvimento desse trabalho, buscou-se bibliotecas de programação de uso gratuito, sem restrições para utilização ou divulgação. Identificou-se que engenheiros e pesquisadores têm desenvolvido diversas ferramentas de código aberto e disponibilizado para a comunidade, visando a simulação de sistemas fotovoltaicos. Entre essas bibliotecas avaliou-se o proposto por Holmgren *et al.* (2018).

A escolha de ferramentas também levou em consideração ampla referência das mesmas em publicações científicas, boa documentação e exemplos de utilização de seus componentes, constante manutenção (correções e aprimoramentos), além do suporte de instituições associadas ao desenvolvimento tecnológico e pesquisa científica.

PVLIB PYTHON é uma ferramenta mantida e documentada pela comunidade que oferece um conjunto de funções e classes para simular o funcionamento de sistema fotovoltaicos (HOLMGREN; HANSEN; MIKOFSKI, 2018; HOLMGREN *et al.*, 2015).

Por utilizar a linguagem de programação PYTHON, pode ser implementado em diversas plataformas de programação, executado sem restrições em vários dispositivos e sistemas operacionais, além de implementado usando infraestrutura em nuvem através da Internet, o que atende ao requisito de ampla disponibilidade e acessibilidade para o ambiente virtual objeto desse trabalho de pesquisa.

Foi possível observar que a última versão estável (0.9.3) é recente, publicada em setembro de 2022 e que desde 2015 já foram publicadas pelo menos 30 atualizações de acordo com registros mantidos por PVLIB *Python Development Team* (2021)³. Também estão disponíveis detalhes sobre os aprimoramentos de cada versão, documentação dos componentes, fórmulas e referência aos artigos científicos nos quais foram baseados. O código-fonte está disponível em repositório público no GITHUB ⁴ conforme indicado por Holmgren *et al.* (2015).

Segundo Stein *et al.* (2016), PVLIB PYTHON foi originalmente adaptado da biblioteca PV_LIB MATLAB *toolbox*, desenvolvido por *Sandia National Laboratories* (SANDIA) a partir de 2009, incluindo muitos dos métodos e modelos criados pelos mesmos.

Em outras referências, foi possível ver a aplicação das bibliotecas em modelos de previsão de geração de energia fotovoltaica a partir de dados de previsão do tempo disponíveis em fontes públicas, bem como a comparação entre resultados simulados com os medidos em experimentos. (HOLMGREN; GROENENDYK, 2016; STEIN *et al.*, 2016)

³ <https://pvlib-python.readthedocs.io/en/stable/whatsnew.html>

⁴ <https://github.com/pvlib/pvlib-python>

3.2. MODELAGEM E SIMULAÇÃO

A modelagem computacional é a área do conhecimento que se dedica a analisar e entender fenômenos nas diversas áreas como engenharia, biologia, economia, etc., buscando soluções para problemas complexos através de modelos matemáticos e técnicas computacionais.

A modelagem com modelos matemáticos é uma abordagem essencial em diversas áreas científicas, permitindo a representação e análise de fenômenos complexos por meio de equações e relações matemáticas. Essa prática contribui para a compreensão mais profunda dos sistemas estudados, possibilitando a previsão de comportamentos, a otimização de processos e a tomada de decisões a partir de resultados de simulações. (LAW, 2014).

Segundo Chung (2004), modelagem pode ser aplicada em:

- a) Análise Dinâmica: possibilitando a observação de como variáveis interagem ao longo do tempo, o que é útil para compreender cenários complexos.
- b) Teste de Cenários: permitem a avaliação de diferentes cenários sem a necessidade de realizar experimentos práticos, permitindo prever resultados sob condições variadas;
- c) Validação de Sistemas: permite validar sistemas antes de sua implementação, permitindo identificar potenciais falhas ou otimizar o desempenho antes da construção física;
- d) Treinamento e Educação: oferecem um ambiente seguro para o ensino de habilidades.


Em resumo, a modelagem por meio de modelos matemáticos, desempenha um papel fundamental na pesquisa científica, permitindo uma compreensão mais profunda e uma abordagem sistemática para entender e interagir com o mundo ao nosso redor.

3.3. PROCESSAMENTO DE IMAGENS DIGITAIS

3.3.1. Estrutura de uma imagem digital e formatos

Uma imagem é a representação visual daquilo que observamos. As cores irão depender da luz incidente e refletida pelos objetos, variando do preto ao branco. Chamamos de imagem digital uma representação discretizada dessa imagem, onde

a mesma é representada por um plano cartesiano (X,Y), conforme a Figura 28, de dimensões finitas e cada posição, chamada de pixel, tem uma intensidade de cor (GONZALEZ;WOODS,2010).



Fonte: Adaptado de KLETTLE (2014).

A combinação das dimensões X e Y é chamada de resolução da imagem e a variação da intensidade de cor ou seja da quantidade de tons ou cores que podem ser atribuídas a um pixel, chamamos de profundidade de cor.


O mais comum é representarmos a intensidade de 8 bits (0 a 255), representando 256 tons de cinza entre o preto (0) e o branco (255), inclusive.

Um dos primeiros padrões criados e o mais utilizado é o RGB que utiliza as três cores primárias (Red=Vermelho, Green=Verde e Blue=Azul) para a formação das outras cores. Para cada par de cores existe um plano (X,Y) o que faz com que no padrão RGB a intensidade de cor seja representada por um vetor (R,G,B) e possa ter $[8 \text{ bits}]^3$ possibilidades, como na Figura 29, resultando em 16.777.216 tons ou cores (GONZALEZ; WOODS, 2010).

Para armazenar a imagem digital o formato principal existente é o BMP (mapeamento de bits), que registra a intensidade de cor de cada posição (X,Y) para um plano cartesiano de dimensões finitas (resolução).

Se a imagem for monocromática (preto e branco), bastará 1 bit ([0-1] para cada pixel. Se forem tons de cinza, serão necessários 8 bits ou 1 byte ([0-255]) para cada pixel, e se for colorida no padrão RGB, serão necessários 24 bits ou 3 bytes ([0-255,0-255,0-255]).

Figura 29 – Profundidade de cor - RGB.



Fonte: Adaptado de KLETTLE (2014).

Isso faz com que imagens de grande resolução exijam maior espaço de armazenamento e consequentemente de processamento.

Outros formatos de imagens foram criados a fim de resolver essa questão, utilizando técnicas de compressão de dados que se aproveitam das características das imagens (repetição e transição entre as cores ao longo do plano) a fim de reduzir a quantidade de informação necessária para representá-la.

O primeiro e amplamente utilizado é o formato JPG, criado pelo *Joint Photographic Experts Group* (JPEG) para o armazenamento principalmente de fotos. Permite a redução significativa do tamanho da imagem, mas pode incorrer numa perda de qualidade com a redução da nitidez, de acordo com a taxa de compactação utilizada durante os processos de gravação da imagem. Com a expansão da WEB e da transferência de imagens digitais, outro formato se popularizou, o *Portable Network Graphics* (PNG), pois oferece perda insignificante no processamento das imagens (KLETTLE, 2014).

3.3.2. Operações com imagens digitais


No processamento de imagens, uma operação muito comum é o redimensionamento de imagens digitais, pois as vezes a resolução original não está de acordo com a resolução que os sistemas computacionais necessitam para

processá-las. Quanto maior a resolução, maior o tamanho da imagem digital e para seu processamento, maior a capacidade computacional necessária.

Para fazer esse redimensionamento é utilizada uma técnica de interpolação matemática com os píxeis, que preenche os espaços a serem acrescentados (quando a imagem é ampliada) ou os espaços adjacentes daqueles que serão removidos (quando a imagem for reduzida), utilizando os valores das intensidades dos pontos adjacentes, buscando sempre a menor perda de informação.

Outra operação importante é a binarização, conversão de imagens coloridas em preto e branco a fim de reduzir o seu tamanho e a quantidade de informações de cores, reduzindo a capacidade computacional necessária para o seu processamento. Uma das primeiras técnicas disponíveis e muito utilizada é a proposta por OTSU (1979) que aplica um valor limite (entre 0 e 255), a partir do qual a intensidade de cor de cada pixel será convertida para preto (0), valores abaixo ou igual ao limite; ou branco (255), valores acima do limite (KLETTLE, 2014)

Na Figura 30 observa-se o exemplo de uma imagem bem nítida (A), sem nenhum tipo de imperfeição ou ruído (B), com algum ruído (C) e posteriormente o resultado aplicando a técnica de OTSU (D), com diferentes valores limite.



Fonte: Adaptado de GONZALEZ e WOODS (2010).

Em ambos os casos, com ou sem ruído, a imagem binarizada resultante preserva a informação relevante desejada, no caso, o contorno da figura.

3.4. REDES NEURAIS ARTIFICIAIS E APRENDIZADO DE MÁQUINA

As Redes Neurais Artificiais (RNA) são sistemas de computação com nós interconectados inspirados nos neurônios do cérebro humano e denominados neurônios matemáticos ou artificiais. Usando algoritmos essas redes podem reconhecer padrões e correlações entre dados e desta forma aprender sobre as relações entre dados de entrada e saída. Como exemplo, pode aprender a analisar


características de um objeto e classifica-lo dentro de um conjunto de opções, ou classes (GOODFELLOW; BENGIO; COURVILLE, 2016).

Esses neurônios artificiais, conforme exemplo na Figura 31, recebem sinais de entrada, que são multiplicados por um peso de conexão, que ponderam a força de um nó específico. O resultado é aplicado numa função de ativação utilizada para determinar a saída de um nó como um "sim" ou "não", mapeando a saída entre 0 ou 1, ou entre -1 e 1. Esse modelo foi chamado de *Perceptron* (MCCULLOCH;PITTS,1943).

Podem ser divididas em (GOODFELLOW; BENGIO; COURVILLE, 2016):

- Linear, quando não restringe a saída entre valores, sendo uma linha reta onde a ativação é proporcional a entrada, usada em problemas de baixa complexidade;
- não-linear, quando facilita a generalização ou a adaptação com grandes variedades de dados, tornando possível solucionar melhor problemas mais complexos.

Figura 31 – Exemplo de neurônio matemático ou artificial.




Fonte: Adaptado de MOL *et al.*(2007)

O valor de saída de um neurônio pode ser usado como entrada para outros neurônios ligados em sequência, ou ter o seu valor interpretado para a solução de um determinado problema (MCCULLOCH;PITTS,1943).

Nestas condições podemos formar redes com uma ou mais camadas, denominadas *Multi-Layer Perceptron* (MLP), conforme exemplo na Figura 32.

Figura 32 – Redes neurais mono (esq.) e multicamadas (dir.).



Fonte: Adaptado de GÉRON *et al.* (2016)

Observa-se também que as camadas estão totalmente conectadas (cada neurônio de uma camada conectado a todos os neurônios da camada seguinte) e que existe apenas um sentido para a informação (para frente ou *feed-forward*).


Uma RNA com mais de duas camadas escondidas é geralmente denominada de rede neural profunda (RNP) e requer um algoritmo mais elaborado para sua solução, dada a maior quantidade de pesos a serem ajustados.

Rumelhart, Hilton e Williams (1985) propuseram um algoritmo chamado “Retro propagação de erros” (ou *backpropagation*) para treinamento de RNA, combinado com o uso de funções de ativação não lineares. Esse algoritmo aplica o algoritmo “Gradiente descendente” de forma recursiva, para minimizar a média do quadrado dos erros (diferença) entre o valor calculado da saída da RNP e os respectivos valores conhecidos para essas saídas, permitindo que a RNP seja utilizada com eficácia em tarefas de classificação (MITCHELL, 1997).

3.4.1. Redes neurais convolucionais (RNC)

As RNC são redes neurais de aprendizado profundo baseadas no mecanismo de percepção visual dos seres vivos, onde a combinação hierárquica de uma estrutura de percepção simples pode funcionar como uma estrutura de percepção complexa (HUBEL; WIESEL, 1968). Para tal são utilizadas camadas sequências que processam as imagens de entrada retirando delas características que permitirão sua identificação ao final do processo. Um exemplo pode ser visto na Figura 33.


Figura 33 – Exemplo de RNA.



Fonte: Adaptado de LECUN *et al.* (1998).

Camada de Convolução : O propósito desta camada é a extração de características de baixo nível da imagem através de operações matriciais com os píxeis. É composta por diversos filtros (kernels), que são aplicados à imagem de entrada. Cada filtro aplicado gera um mapa de saída, que resalta alguma característica na imagem, por exemplo, o contorno dos objetos presentes (KARPATHY *et al.*, 2016). A Figura 34 exemplifica a operação realizada em uma camada de convolução.

Figura 34 – Obtenção de mapa de características numa operação de convolução.




Fonte: Adaptado de KARPATHY *et al.* (2016).

Camada de agrupamento (*pooling*): Visa reduzir o tamanho dos mapas de características considerando a semelhança de valores vizinhos (KARPATHY *et al.*, 2016). Esse objetivo é alcançado ao associar um conjunto de valores adjacentes do mapa de característica anterior a um único valor no novo mapa de característica.

- a) Agrupamento máximo (*max pooling*): retorna apenas o maior valor dentre os valores analisados em cada operação (BOUREAU;PONCE;LECUN, 2010). Um exemplo é mostrado na Figura 35;

- b) Agrupamento médio (*average pooling*): retorna apenas o valor médio dos valores analisados em cada operação (WANG *et al.*, 2012).

Figura 35 – Exemplo de operação de agrupamento (*pooling*).



Fonte: Adaptado de KARPATY *et al.* (2016).

Camadas totalmente conectadas: conforme previstas no modelo tradicional de RNA, recebem as características extraídas anteriormente pelas diversas camadas de convolução e agrupamento e irão interpretá-las com alto nível de abstração e realizar operações complexas como classificar objetos (YOSINSKI *et al.*, 2014).

Camadas de saída: o número de neurônio de saída é igual ao número de opções ou classes de resposta ao problema. Nesta saída se usa uma função de ativação SOFTMAX e a saída representará a probabilidade de compatibilidade da entrada com cada uma das opções de saída, sendo considerada como melhor resultado a saída que apresentar maior valor de probabilidade.

3.4.2. Arquiteturas de RNC implementadas

O modelo RNC inicialmente construído utilizou a arquitetura LENET-5 proposta por LeCun *et al.* (1998), mantendo-se a proposta de camada convolucional.

Na sequência, a fim de se buscar uma melhor capacidade de classificação das curvas, nas diversas condições operacionais propostas, foi utilizada a arquitetura ALEXNET (KRIZHEVSKY; SUTSKEVER; HINTON, 2017) também mantendo-se a proposta de camada convolucional.

Por fim, com o objetivo de verificar se modelos mais complexos poderiam trazer algum ganho, apesar de terem sido desenvolvidos para situações com centenas de

classes distintas e bem diferentes⁵ (imagens de objetos e animais em geral), implementou-se os modelos VGG16, conforme Simonyan e Zisserman (2015) e EfficientNET_V2 conforme Tan e Le (2021), a partir de objetos pré-configurados da biblioteca KERAS⁶.

Em todos os casos, ao final da camada convolucional, manteve-se uma camada totalmente conectada configurável, de forma que pudessem ser alteradas de acordo com as necessidades de cada experimento. Um resumo comparativo pode ser visto no Quadro 3.

Quadro 3 – Arquiteturas de RNC implementadas.

Tipo de Camada Convolucional	Camadas de Filtros	Camadas de Agrupamentos	Função de Ativação	Outros detalhes
LENET-5	2	2	RELU	Originalmente usou Sigmoides como função de ativação.
ALEXNET	5	3	RELU	Utiliza a técnica de normalização dos pesos (<i>batch normalization</i>) após cada agrupamento
VGG16	13	5	RELU	-
EfficientNET - V2S	-	-	RELU	270 camadas ao total entre filtros, agrupamentos, normalização, etc., numa estrutura bem mais complexa.

Fonte: Elaborado pelo autor.

3.4.3. Métricas para avaliação de desempenho

Inicialmente seguem algumas definições importantes usadas em classificação.

- a) Verdadeiros Positivos (V_P): é o número de instâncias positivas classificadas como positivas;
- b) Falsos Positivos (F_P): é o número de instâncias negativas classificadas como positivas;
- c) Verdadeiros Negativos (V_N): é o número de instâncias negativas classificadas como negativas;
- d) Falsos Negativos (F_N), é o número de instâncias positivas classificadas como negativas.

Durante o treinamento e predição das redes, neurais para fins de classificação, algumas métricas foram usadas, a saber:

- a) Taxa de Verdadeiros Positivos (N_{VP}): é a relação entre o número de

⁵ Competição *ImageNet*, com a classificação de 14 milhões de imagens em 1000 classes.

⁶ Acessível em <https://keras.io/api/applications/>

verdadeiros positivos e o total de instâncias positivas, conforme equação (3):

$$N_{VP} = V_P / (V_P + F_P) \quad (3)$$

- b) Taxa de Falsos Positivos (N_{FP}): é a relação entre o número de falso positivos e o total de instâncias positivas, conforme equação (4):

$$N_{FP} = F_P / F_P + V_P \quad (4)$$

- c) Acurácia: é a razão entre o número de acertos e o total de previsões feitas, ou seja, ela é a porcentagem de acertos do modelo, conforme equação (5):

$$\text{Acurácia} = \text{Total de Acertos} / \text{Total de Predições} \quad (5)$$

- d) Precisão: é uma métrica que avalia o quão preciso é o modelo com verdadeiros positivos em relação a falsos positivos, conforme equação (6):

$$\text{Precisão} = V_P / (V_P + F_P) \quad (6)$$

- e) Sensibilidade (Recall): é a capacidade do modelo de identificar os verdadeiros positivos, conforme equação (7):

$$\text{Sensibilidade} = V_P / (V_P + F_N) \quad (7)$$

- f) F1 Score: é uma função que demonstra o quão a Precisão e a Sensibilidade estão equilibradas, ou seja, quando falsos positivos e falsos negativos são igualmente importantes, conforme equação (8):

$$F1\text{Score} = 2 \times (\text{Precisão} \times \text{Sensibilidade}) / (\text{Precisão} + \text{Sensibilidade}) \quad (8)$$

- g) Curva ROC apresenta a performance entre diferentes limites de probabilidade para a predição em um modelo de classificação, usando as taxas de verdadeira positivo e falso positivo. Traçada pela relação N_{VP} por N_{FP} num gráfico de 0 a 1.

- h) AUC: representa a probabilidade de uma instância pertencer a uma classe e é calculada como a área da curva ROC.

- i) Matriz de Confusão: tabela que exhibe a distribuição dos registros ou elementos da análise em termos de suas classes atuais, no eixo vertical e de suas classes previstas, no eixo horizontal. Isso indica a qualidade do modelo atual. A dimensão da tabela será igual ao número de classes do modelo e a expectativa é que o máximo de registros esteja sempre na coluna que corresponde entre a interseção de cada classe em ambos os eixos.

4. MÉTODO DE PESQUISA

4.1. NATUREZA METODOLÓGICA DA PESQUISA

As abordagens de pesquisa são o planejamento e os procedimentos que abrangem desde pressupostos gerais até métodos de coleta, análise e interpretação de dados. Envolvem várias escolhas que não precisam ser feitas na ordem que serão executadas (CRESWELL, 2021).

O trabalho se iniciou com o aprimoramento de ideias através de uma pesquisa exploratória, buscar formular melhor o problema, torná-lo explícito e formular hipóteses (GIL, 2002).

Em função das limitações já apresentadas a respeito das dificuldades em se utilizar equipamentos e realizar experimentos práticos, identificou-se que a pesquisa seria de laboratório. Segundo Marconi (2021), essas pesquisas são realizadas em recintos fechados, inclusive em ambientes artificiais, dependendo do campo da ciência e as experiências se resumem a manipulações limitadas.

Dentre todas as abordagens disponíveis na literatura, identificou-se com as características da experimental quantitativa, que consiste em investigação empírica, cujo objetivo é o teste de hipóteses que dizem respeito a relações de causa e efeito. MARCONI (2021). As hipóteses são proposições verbais que podem ser falsas ou verdadeiras e que consistem em oferecer uma solução possível (GIL, 2002).

Na pesquisa experimental, o pesquisador é um agente ativo e propõe determinar um objeto de estudo, selecionar variáveis que o influenciem e definir formas de controle e observação dos efeitos que as variáveis produzem sobre o objeto Gil (2002). Na abordagem quantitativa, as variáveis são medidas, em geral por instrumentos e seus resultados numéricos são analisados com procedimentos estatísticos. O relatório final tem uma estrutura fixa: introdução, literatura, teoria, métodos, resultados e discussão (CRESWELL, 2021).

Também é destacado por Creswell (2021), alguns pressupostos nesse tipo de abordagem, incluem a criação de barreiras contra viés ou tendenciosidade, o controle de explicações alternativas e a capacidade para generalizar ou replicar os resultados ou conclusões.


4.2. METODOLOGIA GERAL DA PESQUISA

Após os estudos iniciais e o levantamento de trabalhos correlatos, desenvolveu-se algum código computacional e executou-se atividades empíricas exploratórias, definiu-se o fluxo de trabalho para o desenvolvimento da pesquisa a fim de se atingir os objetivos traçados.

O ponto central da pesquisa foi a definição de um modelo matemático e computacional que simulasse condições operacionais a partir do circuito equivalente de um arranjo de painéis fotovoltaicos operando sob diversos cenários, que incluem as variações de temperatura, formato dos arranjos, irradiância (normal ou sob sombras) e a inclusão de anomalias para cada uma delas (mismatch, curto-circuito, circuito aberto).

A Figura 36 apresenta toda a proposta de trabalho até a geração de uma rede neural convolucional (RNC) para classificação.

Figura 36 – Fluxo para criação do modelo de RNC.



Fonte: Elaborado pelo autor.

Cada condição operacional é tratada como uma classe diferente para um classificador baseado em RNC. Ao final, a RNC deve ser capaz de prever com a melhor precisão possível, a qual classe uma determinada curva característica I-V pertence, ou seja, em que condição operacional o arranjo de painéis submetido ao modelo estava operando no momento da geração da curva I-V.


Definiu-se como cenário a operação de um arranjo de painéis fotovoltaicos, de um determinado modelo, sob condições de irradiância e temperatura de célula uniformes.

Definiu-se como amostra, um conjunto de imagens correspondentes a um conjunto de cenários gerados nas diversas condições operacionais do modelo proposto.

Toda a metodologia foi desenvolvida de forma a ser inspecionada ou reproduzida por terceiros, além de permitir sua execução de forma recorrente, dentro da disponibilidade de tempo e recursos computacionais, na busca por resultados cada vez melhores. Para isso todos os parâmetros utilizados ficam registrados, juntamente com evidências da execução de cada experimento.

Na sequência, a Figura 37 apresenta como utilizar a rede RNC para classificar curvas I-V de um arranjo qualquer, apoiando a identificação da condição operacional e consequente diagnóstico de eventuais perdas ou falhas.

Figura 37 – Fluxo para predição com o modelo de RNC gerado.



Fonte: Elaborado pelo autor.

4.2.1. Modelo computacional e condições operacionais do SFV

Após a pesquisa da literatura de estudos similares, suas contribuições e limitações, foi escolhido um conjunto inicial de condições operacionais, considerando as limitações do tema e da pesquisa apresentadas na Seção 1.5.


Em função da irradiação:

- a) Normal: A irradiância em todo o arranjo de painéis fotovoltaicos é uniforme, resultando numa temperatura operacional de célula também uniforme;
- b) Sombras: A irradiância em partes do arranjo de painéis fotovoltaicos é reduzida em função de um padrão de sombras, independentemente da causa: horário do dia, época do ano, obstáculos físicos ou nuvens. A temperatura operacional das células atingidas é ajustada em função da irradiância. Combinações diferentes do formato da sombra são chamados de padrões de sombra;

Em função de possíveis anomalias:

- a) Circuito aberto (CA): O arranjo de painéis fotovoltaicos opera sob cenário de irradiância normal ou sob sombras. Um dos painéis em um dos segmentos, apresenta anomalia de circuito aberto (sem tensão e circulação de corrente elétrica);
- b) Curto-circuito (CC): O arranjo de painéis fotovoltaicos opera sob cenário de irradiância normal ou sob sombras. Um dos painéis em um dos segmentos, apresenta anomalia de curto-circuito (sem geração de tensão elétrica);
- c) Mismatch: O arranjo de painéis fotovoltaicos opera sob cenário de irradiância normal ou sob sombras, além de uma condição uniforme de *mismatch*, independentemente da causa: diferença nas características construtivas, degradação por poeira, trincas, aquecimento ou idade, entre outros;

No Quadro 4 estão listados exemplos das curvas características I-V geradas para todas as combinações de condições operacionais apresentadas acima, sob o cenário com um arranjo de 7x7 painéis fotovoltaicos do modelo CS3W-420, irradiância 1000 [W/m²] e temperatura de 25 [°C], normalizadas entre 0 e 1 nos dois eixos (vertical: I, horizontal: V).

Quadro 4 – Curvas I-V normalizadas nas diferentes condições operacionais.⁷

Fonte: Elaborado pelo autor.


⁷ Eixo horizontal: V, tensão elétrica, entre 0 e 1. Eixo vertical: I, corrente elétrica, entre 0 e 1.

Operando sob essas condições, os arranjos de painéis fotovoltaicos apresentam variações significativas em suas curvas características I-V que permitem a correta classificação proposta das condições operacionais e consequente identificação da ocorrência de perdas (redução da potência produzida por sombras ou mismatch) ou anomalias (curto-circuito, circuito aberto ou *mismatch*).

Maiores detalhes de como as curvas características foram geradas e quais as premissas para cada classe estão disponíveis nas seções a seguir.

4.2.1.1. Arranjo principal dos painéis fotovoltaicos

Decidiu-se utilizar como referência a proposta de arranjo prevista em Bonthagorla e Mikkili (2020), com 7 segmentos (*strings*) em paralelo, formadas por 7 painéis fotovoltaicos em série cada. A Figura 38 apresenta a distribuição dos painéis e a composição das correntes elétricas e tensões do circuito. Observa-se que não foram introduzidos diodos de *by-pass* ou diodos de bloqueio no circuito, conforme esclarecimentos apresentados na Seção 1.5 com as limitações do tema e da pesquisa.



Fonte: Elaborado pelo autor, baseado em Bonthagorla e Mikkili (2020).

A corrente elétrica e a tensão produzida em cada painel (I_{Pon} e V_{Pon} , respectivamente, sendo P_o : ordem do painel no segmento em série e, n : número do segmento no arranjo) dependerão das características do painel fotovoltaico, da irradiância a qual o mesmo estiver submetido (normal ou sob sombras), da

temperatura de operação de suas células fotovoltaicas, além da condição operacional (normal ou sob anomalia de *mismatch*).


O cálculo das correntes elétricas e tensões em cada segmento e de todo o arranjo foi realizado utilizando a composição série-paralelo dos valores, bem como os efeitos da condição operacional (normal ou sob anomalia de circuito aberto ou curto-circuito).

4.2.1.2. Operação normal

Na operação normal, apresentada com um exemplo na Figura 39, considerou-se:

- a) Irradiância uniforme em todos os painéis do arranjo;
- b) Temperatura de célula uniforme em todos os painéis do arranjo;
- c) Nenhuma anomalia nos painéis ou no circuito do arranjo.

Figura 39 – Cenário com irradiância e temperatura de célula uniformes.



Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

A operação normal foi simulada para diversas condições de irradiância e temperatura, considerando ainda uma possível tolerância da potência máxima em alguns cenários.


4.2.1.3. Operação sob sombras

A operação sob sombras foi simulada para diversas condições de temperaturas e para diversos padrões de sombras proposto por Bonthagorla e Mikkili (2020), conforme exemplos nas Figuras 40, 41, 42, 43, 44, 45, 46 e 47. Considerou-se:

- Irradiância reduzida em alguns painéis de acordo com cada padrão de sombra aplicado;
- Irradiância uniforme nos demais painéis do arranjo;
- Temperatura de célula uniforme em todos os painéis do arranjo;
- Nenhuma anomalia nos painéis ou no circuito do arranjo.


A operação sob sombras foi simulada para diversas condições de variação da irradiância e temperatura, sem considerar uma possível tolerância da potência máxima nos cenários, visto que o efeito da sombra irá se sobrepor ao efeito da tolerância.

Figura 40 – Cenário de irradiância com sombra, padrão canto esquerdo.



Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).


Figura 41 – Cenário de irradiância com sombra, central.



Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).


Figura 42 – Cenário de irradiância com sombra, padrão lado direito.



Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).


Figura 43 – Cenário de irradiância com sombra, padrão inferior.



Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

Figura 44 – Cenário de irradiância com sombra, padrão formato “L”.



Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

Figura 45 – Cenário de irradiância com sombra, padrão quadro.

200 [W/m ²] Temperatura	300 [W/m ²] Temperatura	400 [W/m ²] Temperatura	500 [W/m ²] Temperatura	600 [W/m ²] Temperatura	700 [W/m ²] Temperatura	800 [W/m ²] Temperatura
300 [W/m ²] Temperatura	200 [W/m ²] Temperatura	300 [W/m ²] Temperatura	400 [W/m ²] Temperatura	500 [W/m ²] Temperatura	600 [W/m ²] Temperatura	700 [W/m ²] Temperatura
400 [W/m ²] Temperatura	300 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	500 [W/m ²] Temperatura	600 [W/m ²] Temperatura
500 [W/m ²] Temperatura	400 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	400 [W/m ²] Temperatura	500 [W/m ²] Temperatura
600 [W/m ²] Temperatura	500 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	300 [W/m ²] Temperatura	400 [W/m ²] Temperatura
700 [W/m ²] Temperatura	600 [W/m ²] Temperatura	500 [W/m ²] Temperatura	400 [W/m ²] Temperatura	300 [W/m ²] Temperatura	200 [W/m ²] Temperatura	300 [W/m ²] Temperatura
800 [W/m ²] Temperatura	700 [W/m ²] Temperatura	600 [W/m ²] Temperatura	500 [W/m ²] Temperatura	400 [W/m ²] Temperatura	300 [W/m ²] Temperatura	200 [W/m ²] Temperatura

Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

Figura 46 – Cenário de irradiância com sombra, padrão aleatório.

1000 [W/m ²] 25 [°C]	800 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	500 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	500 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	400 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]
300 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	300 [W/m ²] Temperatura
1000 [W/m ²] 25 [°C]	200 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	200 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
600 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	700 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	500 [W/m ²] Temperatura
700 [W/m ²] Temperatura	400 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	300 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	300 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]

Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

Figura 47 – Cenário de irradiância com sombra, padrão diagonal.

200 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
200 [W/m ²] Temperatura	300 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	300 [W/m ²] Temperatura	400 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	400 [W/m ²] Temperatura	500 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	500 [W/m ²] Temperatura	600 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	600 [W/m ²] Temperatura	700 [W/m ²] Temperatura	1000 [W/m ²] 25 [°C]
1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	1000 [W/m ²] 25 [°C]	700 [W/m ²] Temperatura	800 [W/m ²] Temperatura

Irradiação e Temperatura: uniformes em cada painel fotovoltaico ou ajustados de acordo com o padrão de sombras.

Fonte: Elaborado pelo autor, adaptado de Bonthagorla e Mikkili (2020).

4.2.1.4. Operação sob curto-circuito (CC)


Uma anomalia de curto-circuito em um segmento pode ser representada pela interconexão dos dois terminais de um painel fotovoltaico, independentemente da causa (curto-circuito nos diodos de by-pass, deterioração de material isolante, contato de material condutor externo, etc.). Nessas condições, a corrente elétrica produzida pelos demais painéis em série irá atravessar o trecho sob curto-circuito, que terá diferença de tensão igual a zero, conforme mostrado na Figura 48.

Nestas condições foram criadas duas classes de curvas I-V, com as seguintes variações:

- CC_normal: Para um cenário de irradiância normal, foi acrescentada uma anomalia de curto-circuito em um dos segmentos.
- CC_sombras: Para cada cenário de irradiância sob sombra, foi acrescentada uma anomalia de curto-circuito em um dos segmentos.

A operação sob curto-circuito foi simulada para diversas condições de irradiância e temperatura, considerando ainda uma possível tolerância da potência máxima em alguns cenários.

Figura 48 – Cenário de anomalia com curto-circuito em um segmento.



Fonte: Elaborado pelo autor.

4.2.1.5. Operação sob circuito aberto (CA)


Uma anomalia de circuito aberto em um segmento pode ser representada pela interrupção da continuidade elétrica entre os dois terminais de um painel fotovoltaico, independentemente da causa (deterioração de material condutor, ação mecânica com corte de cabos, deterioração ou queima da célula fotoelétrica em série, etc.). Nestas condições, a corrente elétrica produzida pelos demais painéis em série não consegue circular pelo segmento, conforme mostrado na Figura 49.

Assim, foram criadas duas classes de curvas I-V, com as seguintes variações:

- CA_normal: Para um cenário de irradiância normal, foi acrescentada uma anomalia de circuito aberto em um dos segmentos.
- CA_sombras: Para cada cenário de irradiância sob sombra, foi acrescentada uma anomalia de circuito aberto em um dos segmentos.

A operação sob circuito aberto foi simulada para diversas condições de irradiância e temperatura, considerando ainda uma possível tolerância da potência máxima em alguns cenários.

Figura 49 – Cenário de anomalia com circuito aberto em um segmento.



Fonte: Elaborado pelo autor.

4.2.1.6. Operação sob *mismatch*

A palavra *mismatch* é usada principalmente para representar a diferença nos parâmetros operacionais entre painéis de mesma marca, modelo e potência instalados em série ou paralelo. Mas *mismatch* também significa, segundo o dicionário: disparidade, divergência, desajustamento, desequilíbrio, etc. e que podem ser causados por diversos fatores já citados na Seção 3.1.7. Desta forma, decidiu-se agrupar todas essas causas, pois o efeito causado por elas é similar, ou seja, alteração na corrente máxima gerada e consequentemente na potência máxima, não sendo possível separá-los a partir do modelo proposto.

Assim, a operação sob *mismatch* podem ocorrer para as duas condições de variação da irradiância apresentadas nas seções anteriores. Nestas condições foram criadas duas classes de curvas I-V, com as seguintes variações:

- Mismatch_normal*: Para um cenário de irradiância normal, foram consideradas 3 reduções da potência máxima que afetam diretamente os valores da resistência série (R_s) e da resistência paralela (R_{sh}) do circuito equivalente do painel fotovoltaico.
- Mismatch_sombras*: Para cada cenário de irradiância sob sombra, foram

considerados 3 reduções da potência máxima que afetam diretamente os valores da resistência série (R_s) e da resistência paralela (R_{sh}) do circuito equivalente do painel fotovoltaico.

A operação sob mismatch foi simulada para diversas condições de irradiância e temperatura. Não foram consideradas as variações de tolerância da potência máxima indicadas pelos fabricantes, visto que o efeito do mismatch proposto já incorpora tal variação.

4.2.1.7. Desdobramento da operação sob *mismatch*

Durante a pesquisa foi identificado que o mismatch pode ser caracterizado por diversos fatores, inclusive a degradação em função da idade do equipamento. A Figura 50 mostra a expectativa de redução da potência máxima com o tempo de vida útil de um painel Intelbras EMSB-455-HC.

Figura 50 – Potência assegurada por tempo de vida útil.



Fonte: Adaptado de Intelbras (2023b).

Desta forma, pode-se dizer que ele estará sempre presente, numa menor ou maior proporção. Suas consequências, em geral uma redução da potência máxima gerada, poderão ser confundidas com uma redução da irradiância, seja natural ou por sombreamento, ou pela tolerância na potência máxima de cada painel do arranjo, em função das técnicas e materiais utilizados na fabricação.

Uma anomalia de curto-circuito ou de um circuito aberto podem ocorrer a qualquer tempo num equipamento elétrico, principalmente considerando que o mesmo opera ao ar livre, sob todo tipo de condição climática e sujeito a ação de elementos externos, como poeira, aves, entre outros.


Nestas condições foram criadas mais quatro classes de curvas I-V, com as seguintes variações:

- a) *Mismatch_normal_CC*: combinação das anomalias de *mismatch* e curto-circuito agindo simultaneamente, com irradiação normal.
- b) *Mismatch_sombras_CC*: combinação das anomalias de *mismatch* e curto-circuito agindo simultaneamente, com irradiação sob sombras
- c) *Mismatch_normal_CA*: combinação das anomalias de *mismatch* e circuito aberto agindo simultaneamente, com irradiação normal.
- d) *Mismatch_sombras_CA*: combinação das anomalias de *mismatch* e circuito aberto agindo simultaneamente, com irradiação sob sombras.

4.2.1.8. Capacidade de predição com o modelo matemático

Um dos objetivos quando se faz o treinamento de uma RNC é obter uma boa capacidade de generalização, ou seja, conseguir alta precisão na predição utilizando dados que não fizeram parte do treinamento (ANDREW,2018)

No Quadro 5, pode-se notar a similaridade que existe entre as curvas características I-V de diferentes painéis, normalizadas entre 0 e 1 nos dois eixos (vertical: I, horizontal: V), geradas na mesma condição operacional sob o cenário de irradiância 1000 [W/m²] e temperatura 45 [°C].

Quadro 5 – Curvas I-V geradas com diferentes painéis fotovoltaicos.⁸


Fonte: Elaborado pelo autor.

Desta forma, espera-se treinar a RNC com uma quantidade limitada de painéis e depois conseguir prever a condição operacional de outros modelos com boa precisão.

Os grupos de painéis fotovoltaicos utilizados nessa pesquisa estão disponíveis na seção 4.2.3.1.

No Quadro 6, pode-se notar a similaridade de formato que existe entre as curvas características I-V, normalizadas entre 0 e 1 nos dois eixos (vertical: I, horizontal: V), utilizando o painel CS7N-640, num arranjo 7x7, temperatura de 25 [°C], para diversas irradiâncias. As curvas possuem amplitudes diferentes mas largura similar, como se fossem achatadas na medida que a irradiância diminui, reduzindo a corrente máxima produzida quando a tensão é nula (condição de curto-circuito da célula).

⁸ Eixo horizontal: V, tensão elétrica, entre 0 e 1. Eixo vertical: I, corrente elétrica, entre 0 e 1.

Quadro 6 – Curvas I-V geradas para irradiâncias diferentes. ⁹

Fonte: Elaborado pelo autor.

Desta forma, espera-se treinar a RNC com uma quantidade limitada de irradiâncias e depois conseguir prever a condição operacional sob outras condições, com boa precisão. Todos os grupos de irradiâncias utilizados nessa pesquisa estão listados na Seção 4.2.3.3.


No Quadro 7, pode-se notar a similaridade de formato que existe entre as curvas características I-V, normalizadas entre 0 e 1 nos dois eixos (vertical: I, horizontal: V), utilizando o painel KC200GT, num arranjo 7x7, irradiância de 600 [W/m²], para diversas temperaturas. As curvas possuem amplitudes similares mas largura diferente, como se encolhessem na medida que a temperatura aumenta, reduzindo a tensão máxima sem carga com corrente gerada nula (condição da célula com circuito em aberto).

Desta forma, espera-se treinar a RNC com uma quantidade limitada de temperaturas e depois conseguir prever a condição operacional sob outras

⁹ Eixo horizontal: V, tensão elétrica, entre 0 e 1. Eixo vertical: I, corrente elétrica, entre 0 e 1.

circunstâncias, com boa precisão. Todos os grupos de temperaturas utilizados nessa pesquisa estão listados na Seção 4.2.3.2.

Quadro 7 – Curvas I-V geradas em temperaturas diferentes.¹⁰




Fonte: Elaborado pelo autor.

Os primeiros experimentos foram realizados a partir do arranjo de 7 segmentos com 7 painéis em série em cada (7 x 7), proposto por Bonthagorla e Mikkili (2020).

Na sequência, avaliou-se a capacidade do modelo de prever as condições operacionais de arranjos diferentes de painéis. Por fim, ampliou-se a base de dados de curvas para aprimorar o treinamento do modelo e aperfeiçoar sua capacidade de generalização.

No Quadro 8, tem-se uma comparação das curvas I-V, normalizadas entre 0 e 1 nos dois eixos (vertical: I, horizontal: V), utilizando o painel KU265-6MCA, irradiância de 800 [W/m²], temperatura de 55 [°C], para diferentes arranjos. Observa-se que as curvas possuem diferenças visíveis, o que demonstra antecipadamente que a generalização da capacidade de predição em relação aos arranjos é um desafio.

¹⁰ Eixo horizontal: V, tensão elétrica, entre 0 e 1. Eixo vertical: I, corrente elétrica, entre 0 e 1.

Quadro 8 – Curvas I-V de um painel geradas para diferentes arranjos.¹¹


Fonte: Elaborado pelo autor.

¹¹ Eixo horizontal: V, tensão elétrica, entre 0 e 1. Eixo vertical: I, corrente elétrica, entre 0 e 1.

4.2.2. Fluxo da geração de amostras de curvas I-V

A Figura 51 apresenta como uma única curva I-V é gerada a partir de diversos parâmetros e condições operacionais.

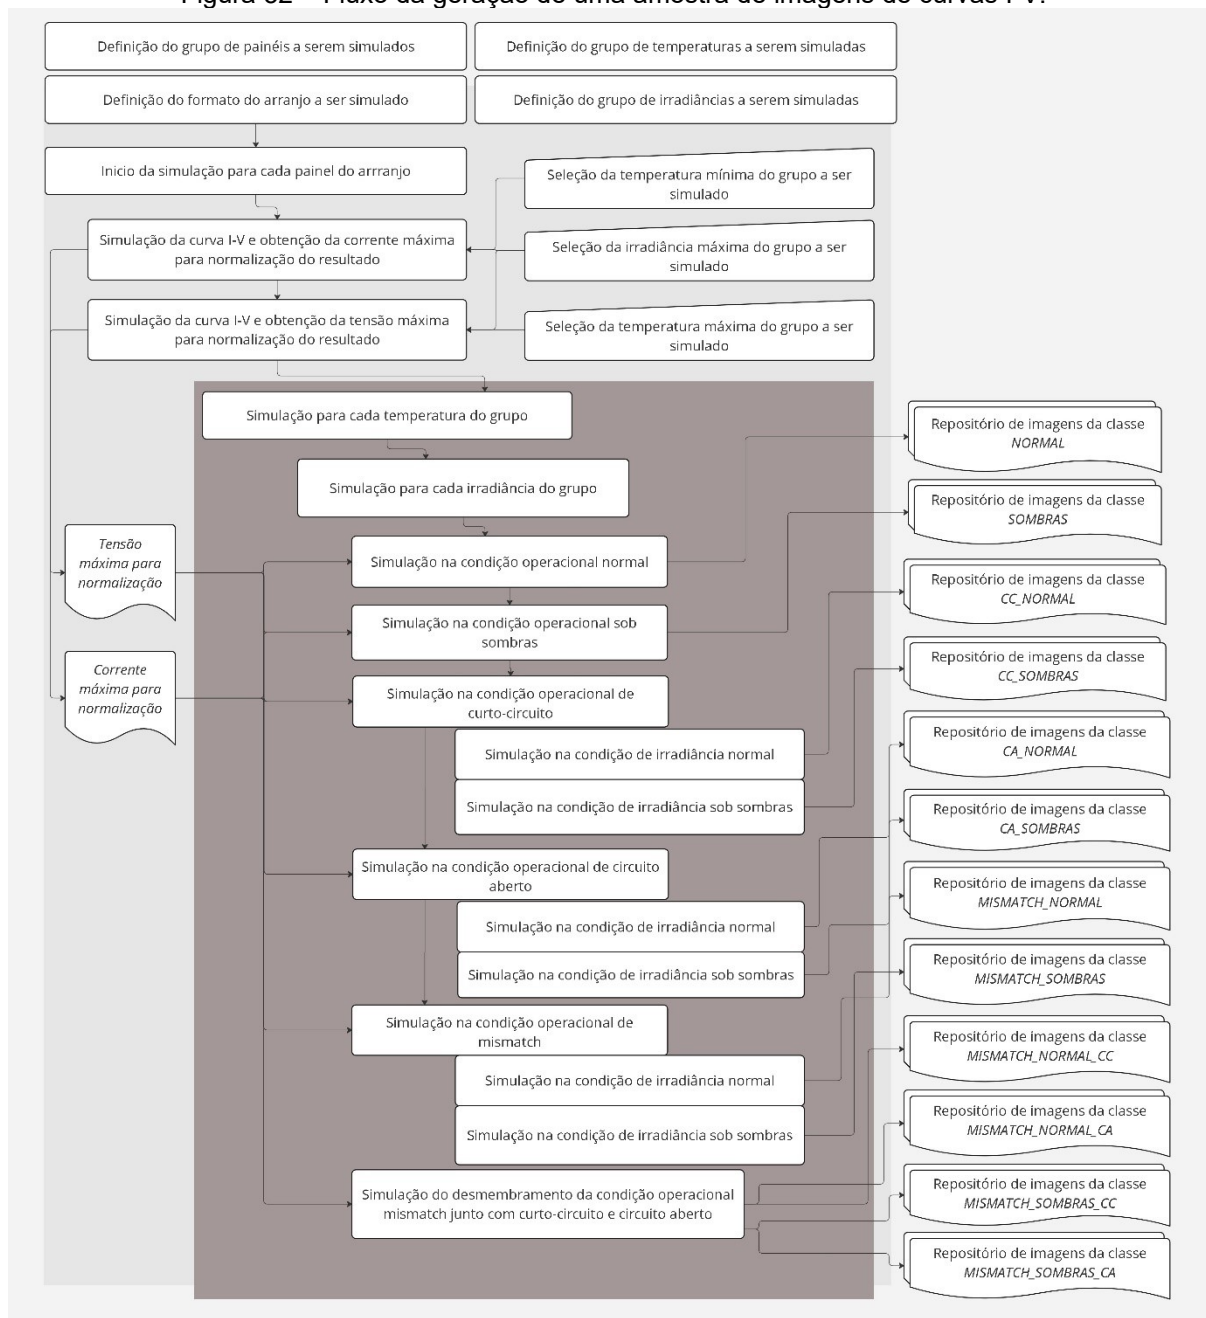
Figura 51 – Fluxo de geração de uma curva I-V



Fonte: Elaborado pelo autor.

A Figura 52 apresenta o processo estruturado de geração de imagens para a criação de uma amostra de curvas I-V, sob diversas condições operacionais, devidamente classificada.

Figura 52 – Fluxo da geração de uma amostra de imagens de curvas I-V.



Fonte: Elaborado pelo autor.

4.2.3. Parâmetros utilizados na geração das curvas características

4.2.3.1. Seleção de painéis fotovoltaicos

Os painéis fotovoltaicos possuem vida útil entre 20 e 30 anos e estão em constante aperfeiçoamento da eficiência e potência máxima de geração, em função da evolução da engenharia dos materiais e técnicas de montagem. Painéis lançados no início desse século ainda estão em operação e podem existir modelos similares aperfeiçoados, disponíveis para aquisição.

Os Laboratórios SANDIA têm uma lista com as características de mais de 21.000 painéis fotovoltaicos de todo o mundo. Uma análise detalhada dessa base de dados e o estabelecimento de critérios para sua seleção, demandariam grande esforço.

Desta forma, decidiu-se por iniciar os estudos da forma mais aleatória possível. Inicialmente, selecionou-se alguns painéis citados em artigos, principalmente naqueles de onde existiam informações relevantes para validação do modelo computacional, como o modelo Kyocera KC200GT (KYOCERA, 2023), utilizado por Bonthagorla e Mikkili (2020).

Na sequência, buscou-se “painéis fotovoltaicos” na Internet, através do buscador do Google, considerando que o mesmo apresenta geralmente tópicos de maior relevância ou que possuem anúncios pagos.

Por fim, buscou-se evoluções de painéis que já tinham sido selecionados, pois em geral apresentavam maior eficiência e maior potência de geração para a mesma quantidade e tipo de células fotovoltaicas.

A Figura 53 mostra um exemplo de ficha técnica do painel Intelbras EMSB-535M HC.

Figura 53 – Exemplo de ficha técnica de painel fotovoltaico EMSB-535M HC.

Especificações técnicas	
Modelo	EMSB-535M HC
Registro INMETRO	Registro 006029/2021 (Portaria nº 004/2011)
PERFORMANCE EM STC ¹	
Potência máxima	535 W
Tensão máxima de operação	41,45 V
Corrente máxima de operação	12,91 A
Tensão de circuito aberto	49,31 V
Corrente de curto circuito	13,79 A
Eficiência do módulo	20,7 % ²
¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m ² , AM de 1,5 e temperatura do módulo de 25°C. ² Equivalente à 207,36 Wp/m ² .	
CARACTERÍSTICAS DE TEMPERATURA	
Coefficiente de temperatura máxima (P _{max})	-0,36 %/°C
Coefficiente de temperatura (V _{oc})	-0,29 %/°C
Coefficiente de temperatura (I _{sc})	+0,048 %/°C
Temperatura nominal do módulo (NMOT)	41±3°C

Fonte: Adaptado de INTELBRAS (2023a).

Ao final, fez-se um filtro de forma que o conjunto de painéis tivesse modelos de diferentes características construtivas (material e quantidade de células), fabricantes, potências máximas e eficiências. Para cada um deles foi acessada a ficha técnica (*datasheet*) e extraídos os parâmetros operacionais necessários para o cálculo do modelo matemático do diodo único.

Os painéis fotovoltaicos foram utilizados em procedimentos, divididos em fases, conforme detalhamento na seção 4.2.4. A Tabela 4 relaciona aqueles utilizados no treinamento da Fase 1, chamado de Grupo GP1. A Tabela 5 lista os utilizados para teste nas Fase 1 e 2, chamados de Grupo GP2 e que posteriormente foram usados na base de treinamento da Fase 3.

Tabela 4 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP1

Identificação			Parâmetros Elétricos						
Modelo (Fabricante)	Potência [W] (Eficiência)	Tecnologia (Nº Células)	I _{CC} [A]	V _{CA} [V]	I _{MP} [A]	V _{MP} [V]	Alfa [V/°C]	Beta [A/°C]	Gama [W %/°C]
KC200GT (Kyocera)	200 (-)	Policristalino (54)	8,21	32,90	7,61	26,30	0,00318	-0,1230	-0,38
KU265-6MCA (Kyocera)	265 (-)	Policristalino (60)	9,26	38,30	8,55	31,00	0,00556	-0,1379	-0,45
TSM-DE18M-480 (Trina Solar)	480 (20,1%)	Monocristalino (150)	11,99	50,80	11,42	42,00	0,00480	-0,1321	-0,36
LR5-72HPH-530 (Longi)	530 (20,7%)	Monocristalino (144)	13,71	49,20	12,82	41,35	0,00658	-0,1328	-0,35
ODA144-PH (OSDA Solar)	415 (19,09%)	Policristalino (144)	11,16	47,64	10,58	39,24	0,00658	-0,1520	-0,38
JAM72S30-525 (JÁ Solar)	525 (20,3%)	Monocristalino (144)	13,65	49,15	12,76	41,15	0,00614	-0,1352	-0,35
CS3W-420 (CanadianSolar)	420 (19,0%)	Policristalino (144)	11,26	48,00	10,64	39,50	0,00563	-0,1344	-0,36
ODA330-36-P (OSDA Solar)	330 (17,0%)	Policristalino (72)	9,33	45,64	8,86	37,26	0,00532	-0,1118	-0,40
CS7N-660 (CanadianSolar)	660 (20,6%)	Monocristalino (132)	18,45	45,4	17,24	38,3	0,00923	-0,1180	-0,34
LN VH-595 (Luxen Solar)	595 (20,57%)	Monocristalino (144)	14,63	51,21	13,64	43,62	0,00732	-0,1434	-0,36

Fonte: Elaborado pelo autor.

Tabela 5 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP2

Identificação			Parâmetros Elétricos						
Modelo (Fabricante)	Potência [W] (Eficiência)	Tecnologia (Nº Células)	I _{CC} [A]	V _{CA} [V]	I _{MP} [A]	V _{MP} [V]	Alfa [V/°C]	Beta [A/°C]	Gama [W %/°C]
TSM-DE18M-505 (Trina Solar)	505 (21,1%)	Monocristalino (150)	12,35	51,90	11,75	43,00	0,00494	-0,1349	-0,35
JAM72S30-550 (JA Solar)	550 (21,3%)	Monocristalino (144)	14,00	49,90	13,11	41,96	0,00630	-0,1372	-0,35
CS3W-395 (Canadian Solar)	395 (19,0%)	Policristalino (144)	10,82	47,00	10,26	38,50	0,00541	-0,1316	-0,36
EMSB-535M HC (Intelbras)	535 (20,7%)	Monocristalino (144)	13,79	49,31	12,91	41,45	0,00662	-0,1429	-0,36
EMSB-455 HC (Intelbras)	455 (21,8%)	Monocristalino (120)	13,95	41,24	13,07	34,82	0,00669	-0,1196	-0,36

Fonte: Elaborado pelo autor.

A Tabela 6 relaciona os painéis fotovoltaicos utilizados no treinamento da Fase 3, chamados de Grupo GP3. Os painéis da Tabela 7, chamados de Grupos GP4, foram usados apenas para teste de generalização da rede neural final na Fase 3.

Tabela 6 – Parâmetros elétricos de painéis fotovoltaicos – Grupo GP3

Identificação			Parâmetros Elétricos						
Modelo (Fabricante)	Potência [W] (Eficiência)	Tecnologia (Nº Células)	I _{CC} [A]	V _{CA} [V]	I _{MP} [A]	V _{MP} [V]	Alfa [V/°C]	Beta [A/°C]	Gama [W %/°C]
CS3W-455 (Canadian Solar)	455 (20,6%)	Monocristalino (144)	11,66	49,30	11,02	41,30	0,00583	-0,1331	-0,35
ZXM7-SHLD144-530	530 (20,5%)	Monocristalino (144)	13,66	49,30	12,94	41,00	0,00683	-0,1429	-0,35
CS6W-550MB-AG-660 (Canadian Solar)	660 (25,7%)	Monocristalino (144)	16,80	49,60	15,40	41,70	0,0084	-0,12891	-0,34
JAM72S10-390 (JA Solar)	390 (19,4%)	Monocristalino (144)	10,23	49,01	9,58	40,71	0,00450	-0,1333	-0,35
ZXP6-H156-375	375 (17,4%)	Policristalino (156)	9,34	51,101	9,00	41,70	0,00560	-0,1584	-0,39
CS6W-545 (Canadian Solar)	545 (21,3%)	Monocristalino (144)	13,95	49,40	13,23	41,20	0,00697	-0,1334	-0,35
EMSL-590M HC (Intelbras)	590 (21,3%)	Monocristalino (156)	13,94	53,70	13,17	44,80	0,00697	-0,1254	-0,36
TSM-380-DE09.05 (Trina Solar)	380 (19,8%)	Monocristalino (120)	12,00	40,40	11,38	33,40	0,00480	-0,1010	-0,34
TSM-DE19R-570 (Trina Solar)	570 (21,1%)	Monocristalino (132)	15,85	45,80	14,79	38,50	0,00634	-0,1145	-0,34
WS485M10-66H (Win Seven)	485 (20,4%)	Monocristalino (132)	13,59	45,48	12,81	37,86	0,00625	-0,1258	-0,35

Fonte: Elaborado pelo autor.

Tabela 7 – Parâmetros elétricos dos painéis fotovoltaicos – Grupo GP4

Identificação			Parâmetros Elétricos						
Modelo (Fabricante)	Potência[W] (Eficiência)	Tecnologia (Nº Células)	I _{CC} [A]	V _{CA} [V]	I _{MP} [A]	V _{MP} [V]	Alfa [V/°C]	Beta [A/°C]	Gama [W %/°C]
ODA580-36V-MH (OSDA Solar)	580 (22,5%)	Monocristalino (144)	14,46	51,06	13,69	42,37	0,00665	-0,1276	-0,30
CS6W-520 (Canadian Solar)	520 (20,2%)	Monocristalino (144)	13,70	48,40	12,84	40,50	0,00685	-0,1258	-0,34
ZXM6-NH144-445	445 (20,4%)	Monocristalino (156)	11,40	50,10	10,81	41,20	0,0057	-0,1452	-0,36
WS650M12-66H	650 (20,92%)	Monocristalino (132)	18,35	45,68	17,23	37,75	0,00844	-0,1215	-0,35
JAM72D20-465 (JA Solar)	465 (20,9%)	Monocristalino (144)	11,55	50,50	11,05	42,90	0,00508	-0,1373	-0,35

Fonte: Elaborado pelo autor.

4.2.3.2. Seleção de temperaturas

A faixa operacional de temperaturas de um painel fotovoltaico é ampla, conforme exemplo que pode ser visto na Figura 54, porém, os valores extremos não são comuns e estão longe das condições nominais de operação, conhecidas como NMOT.

Figura 54 – Limite operacionais de painel fotovoltaico.


Especificações técnicas

Modelo	EMSB-455 HC
PERFORMANCE EM STC¹	
Potência máxima	455 W
Tensão máxima de operação	34,82 V
Corrente máxima de operação	13,07 A
Tensão de circuito aberto	41,24 V
Corrente de curto circuito	13,95 A
Eficiência do módulo	21,08 % ²
¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m ² , AM de 1,5 e temperatura do módulo de 25°C.	
² Equivalente à 210,84 Wp/m ² .	
PERFORMANCE EM NMOT³	
Potência máxima	342,0 W
Tensão máxima de operação	32,45 V
Corrente máxima de operação	10,54 A
Tensão de circuito aberto	39,20 V
Corrente de curto circuito	11,25 A
³ Sob Condições de Temperatura Nominal de Operação Do Módulo (NMOT): irradiância de 800 W/m ² , AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.	

Fonte: Adaptado de Intelbras (2023b).

Buscou-se nas diversas fichas técnicas dos painéis selecionados, as temperaturas operacionais para os quais os fabricantes traçaram as curvas características I-V, como exemplo que pode ser visto na Figura 55, referente ao painel Canadian Solar CS7N-640.

Figura 55 – Exemplo de curvas I-V em catálogos de painéis fotovoltaicos.



Fonte: Adaptado de CanadianSolar (2023).


O grupo de temperaturas selecionadas e que será usado na configuração dos cenários em [°C], é:

a) Grupo GT1: 5, 25, 45, 55, 70, 10, 40, 50, 65, 75.

4.2.3.3. Seleção de irradiâncias

Seguindo o mesmo critério para temperaturas, buscou-se nas diversas fichas técnicas dos painéis selecionados, as irradiâncias para os quais os fabricantes traçaram as curvas características I-V, como pode ser visto no exemplo na Figura 56, referente ao painel Intelbras EMSB-535M HC.

Figura 56 – Exemplo de curvas I-V em catálogos de painéis fotovoltaicos.



Fonte: Adaptado de Intelbras (2023a).

Os grupos de irradiâncias selecionadas e que serão usadas na configuração dos cenários, em [W/m²], são:

a) Grupo GI1: 200, 400, 600, 800, 1000.

- b) Grupo GI2: 200, 250, 300, 350, 400, 450, 500, 550, 600, 650, 700, 750, 800, 850, 900, 950, 1000, 1050, 1100, 1150.

4.2.4. Planejamento dos experimentos

As atividades constituem basicamente da execução de experimentos em ambiente computacional, usando amostras digitais de curvas características I-V, criadas para diversos cenários e simulando as diversas condições operacionais.

O resultado da simulação de cada cenário é uma curva característica I-V normalizada com valores entre 0 e 1, considerando os valores máximos de corrente e tensão para cada arranjo fotovoltaico, registrada em uma imagem digital (.PNG) e armazenada numa pasta correspondente a cada condição operacional.

A normalização é importante, pois para um mesmo modelo de painel, combinado em diversos arranjos, operando nas mesmas condições, são geradas curvas I-V praticamente idênticas, o que permite identificar eventuais divergências no traçado das curvas I-V, usando as técnicas de RNC.

A fim de garantir que o modelo de RNC treinado tenha boa capacidade de generalização, importante objetivo dessa pesquisa, para o treinamento foi decidido usar a técnica de validação cruzada, deixando 80% dos cenários para os ajustes dos pesos do modelo (treinamento em si) e 20% para a validação, após cada época de treinamento (ciclo de treinamento que envolve todos os cenários da amostra reservada para treinamento).

Além disso, foi construído uma base complementar para teste, que complementa cada amostra, utilizando irradiâncias e painéis fotovoltaicos que não fizeram parte dos cenários de treinamento, resultando ao final numa amostra dividida, aproximadamente, 70% de cenários para treinamento e 30% para teste.

Para a composição das bases de teste, foram criadas as seguintes variações:

- a) Base de teste T1: ajustadas as irradiâncias com $+75 \text{ [W/m}^2\text{]}$ e demais parâmetros mantidos de acordo com a amostra de treinamento correspondente. Para manter a proporção de cenários entre as massas de treinamento e testes (70%-30%), alguns cenários foram gerados apenas com temperaturas de 25 e 55 $^{\circ}\text{C}$.
- b) Base de teste T2: usados os painéis do grupo GP4 e mantidos os demais parâmetros de acordo com a amostra de treinamento correspondente. Para manter a proporção de cenários entre as massas de treinamento e testes

(70%-30%), alguns cenários foram gerados apenas com temperaturas de 5, 25 e 55, 75 [°C].

No início do planejamento, observou-se que havia um desbalanceamento na quantidade de elementos de cada classe, conforme Seção 4.2.4.1. Uma das técnicas sugeridas na literatura é a ampliação ou redução da quantidade de elementos por classe a fim de evitar que uma classe tenha predominância sobre as demais.

Nestas condições, decidiu-se ampliar o modelo matemático do circuito equivalente para simular um conjunto mais detalhado de condições operacionais (classes). A nova proposta de balanceamento pode ser vista na Seção 4.2.4.2.

Como não era possível saber qual dos modelos seria viável, decidiu-se planejar 3 fases de execução de experimentos: fase 1, para validar o modelo com 8 classes; fase 2, para validar o modelo com 12 classes; e por fim, fase 3, para otimizar o melhor dos modelos.

4.2.4.1. Fase 1 - Validação do modelo com 8 classes

Nesta fase foram definidos, conforme as Tabelas 8 e 9, a quantidade de parâmetros aplicados a cada painel fotovoltaico submetido ao modelo do circuito equivalente que modela 8 condições operacionais (classes), bem como a composição proporcional de cada classe nas amostras.

Tabela 8 – Variação de parâmetros, por painel – Fase 1

Condição operacional (classe)	Quant. de Irradiâncias	Quant. de Temperaturas	Quant. de Padrões de sombras	Quant. De Tolerâncias de Potência	Segmentos com anomalia	Quant. de imagens
Normal	5	10	-	-	-	50
Sombras	-	10	8	-	-	80
Mismatch_normal	5	10	-	-10%,-15%,-20%	-	150
Mismatch_sombras	-	10	8	-10%,-15%,-20%	-	240
CA_normal	5	10	-	-	1	50
CA_sombras	-	10	8	-	1	80
CC_normal	5	10	-	-	1	50
CC_sombras	-	10	8	-	1	80
Total						780

Fonte: Elaborado pelo autor.

Tabela 9 – Composição das amostras, por painel, por arranjo – Fase 1

Condição operacional (classe)	Cenários (% da amostra)	Condição operacional (classe)	Cenários (% da amostra)
Normal (Normal)	50 (6,4%)	Sombras (Sombras)	80 (10,3%)
Normal sob Mismatch (Mismatch_normal)	150 (19,2%)	Sombras sob Mismatch (Mismatch_sombras)	240 (30,7%)
Normal sob Curto-Circuito (CC_normal)	50 (6,4%)	Sombras sob Curto-Circuito (CC_sombras)	80 (10,3%)
Normal sob Circuito Aberto (CA_normal)	50 (6,4%)	Sombras sob Circuito Aberto (CA_sombras)	80 (10,3%)
1 Painel x 1 Arranjo x 5 Irradiações x 10 Temperaturas = 780 Cenários Média do percentual de elementos por classe: 12,5%; Desvio padrão: 8,47; Variância: 62,78			

Fonte: Elaborado pelo autor.

Por fim, na Tabela 10 tem-se os parâmetros selecionados para a geração das amostras planejadas nesta fase e o total de cenários previstos para treinamento, considerando a simulação com 10 painéis diferentes. As amostras A.2 e A.4 tiveram a quantidade de cenários multiplicados por 5 em função da quantidade de diferentes arranjos. As amostras A.3 e A.4 tiveram a quantidade de cenários multiplicados por 20 em função da quantidade de diferentes irradiâncias.

Tabela 10 – Parâmetros selecionados para cenários de treinamento – Fase 1

Amostra	Classes	Nº e grupo de Temperaturas [°C]	Nº e grupo de Irradiâncias [W/m²]	Nº e tipos de Arranjos	Nº e grupos de Painéis	Nº de Cenários
A.1	8	10 (GT1)	5 (GI1)	1 (7x7)	10 (GP1)	7.800
A.2	8	10 (GT1)	5 (GI1)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	10 (GP1)	39.000
A.3	8	10 (GT1)	20 (GI2)	1 (7x7)	10 (GP1)	31.200
A.4	8	10 (GT1)	20 (GI2)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	10 (GP1)	156.000

Fonte: Elaborado pelo autor.

4.2.4.2. Fase 2 – Validação do modelo com 12 classes

Nesta fase foram definidos, conforme as Tabelas 11 e 12, a quantidade de parâmetros aplicados a cada painel fotovoltaico submetido ao modelo do circuito equivalente que modela 12 condições operacionais (classes), bem como a composição proporcional de cada classe nas amostras.

Tabela 11 – Variação de parâmetros , por painel – Fase 2

Condição operacional (classe)	Quant. de Irradiâncias	Quant. de Temperaturas	Quant. de Padrões de sombras	Quant. de Tolerâncias de Potência	Segmentos com anomalia	Quant. de imagens
Normal	5	10	-	0 e -5%	-	100
Sombras	-	10	8	0 e -5%	-	160
<i>Mismatch_normal</i>	5	10	-	-10%,-15%,-20%	-	150
<i>Mismatch_sombras</i>	-	10	8	-10%,-15%,-20%	-	240
CA_normal	5	10	-	0 e -5%	1	100
CA_sombras	-	10	8	0 e -5%	1	160
CC_normal	5	10	-	0 e -5%	1	100
CC_sombras	-	10	8	0 e -5%	1	160
<i>Mismatch_normal_CC</i>	5	10	-	-10%,-15%,-20%	1	150
<i>Mismatch_sombras_CC</i>	-	10	8	-10%,-15%,-20%	1	240
<i>Mismatch_normal_CA</i>	5	10	-	-10%,-15%,-20%	1	150
<i>Mismatch_sombras_CA</i>	-	10	8	-10%,-15%,-20%	1	240
Total						1950

Fonte: Elaborado pelo autor.

Tabela 12 – Composição das amostras, por painel, por arranjo

Condição operacional (classe)	Cenários (% da amostra)	Condição operacional (classe)	Cenários (% da amostra)
Normal (Normal)	100 (5,1%)	Sombras (Sombras)	160 (8,2%)
Normal sob Mismatch (<i>Mismatch_normal</i>)	150 (7,7%)	Sombras sob Mismatch (<i>Mismatch_sombras</i>)	240 (12,3%)
Normal sob Mismatch e Curto-Circuito (<i>Mismatch_normal_CC</i>)	150 (7,7%)	Sombras sob Mismatch e Curto-Circuito (<i>Mismatch_sombras_CC</i>)	240 (12,3%)
Normal sob Mismatch e Circuito Aberto (<i>Mismatch_normal_CA</i>)	150 (7,7%)	Normal sob Mismatch e Circuito Aberto (<i>Mismatch_sombras_CA</i>)	240 (12,3%)
Normal sob Curto-Circuito (<i>CC_normal</i>)	100 (5,1%)	Sombras sob Curto-Circuito (<i>CC_sombras</i>)	160 (8,2%)
Normal sob Circuito Aberto (<i>CA_normal</i>)	100 (5,1%)	Sombras sob Circuito Aberto (<i>CA_sombras</i>)	160 (8,2%)
1 Painel x 1 Arranjo x 5 irradiâncias x 10 Temperaturas = 1950 Cenários			
Média do percentual de elementos por classe: 8,33%; Desvio padrão: 2,69; Variância: 6,658			

Fonte: Elaborado pelo autor.

Por fim, na Tabela 13 temos os parâmetros selecionados para a geração das amostras planejadas nesta fase e o total de cenários previstos para treinamento, considerando a simulação com 10 painéis diferentes. As amostras A.6 e A.8 tiveram a quantidade de cenários multiplicados por 5 em função da quantidade de arranjos e as amostras A.7 e A.8 tiveram a quantidade de cenários multiplicados por 4 em função da quantidade de irradiâncias ($4 \times 5 = 20$).

Tabela 13 – Parâmetros selecionados para cenários de treinamento – Fase 2

Amostra	Classes	Nº e grupos de Temperaturas [°C]	Nº e grupos de Irradiâncias [W/m²]	Nº e tipos de Arranjos	Nº e grupos de Painéis	Nº de Cenários
A.5	12	10 (GT1)	5 (GI1)	1 (7x7)	10 (GP1)	19.500
A.6	12	10 (GT1)	5 (GI1)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	10 (GP1)	97.500
A.7	12	10 (GT1)	20 (GI2)	1 (7x7)	10 (GP1)	78.000
A.8	12	10 (GT1)	20 (GI1)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	10 (GP1)	390.000

Fonte: Elaborado pelo autor.

4.2.4.3. Fase 3 – Validação do modelo com melhor resultado

Por fim, na Tabela 14 temos os parâmetros selecionados para a geração das amostras planejadas nesta fase e o total de cenários previstos para treinamento, considerando a simulação com 25 painéis diferentes. A amostra A.10 teve a quantidade de cenários multiplicados por 5 em função da quantidade de arranjos e as a quantidade de cenários multiplicados por 4 em função da quantidade de irradiâncias (4x5=20).

Tabela 14 – Resumo de parâmetros para – 12 classes – Fase 3

Amostra	Classes	Nº e grupos de Temperaturas [°C]	Nº e grupos de Irradiâncias [W/m²]	Nº e tipos de Arranjos	Nº e grupos de Painéis	Nº de Cenários
A.9	12	10 (GT1)	20 (GI2)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	25 (GP1+GP2+GP3)	195.000
A.10	12	10 (GT1)	20 (GI2)	5 (7x7, 3x16, 4x12, 5x9, 6x8)	25 (GP1+GP2+GP3)	975.000

Fonte: Elaborado pelo autor.

4.2.5. Procedimento de execução de um experimento

Chama-se experimento o procedimento de gerar uma amostra de imagens que representa um conjunto de cenários específico, treinar um modelo de RNC e avaliar sua capacidade de generalização a partir de bases de teste. O procedimento é dividido basicamente em 3 etapas.

Etapa 1: Geração das amostras de curvas I-V:

- Selecionar um ou mais grupos de painéis fotovoltaicos, selecionar um ou mais combinações de arranjos (S x M), selecionar um ou mais grupos de

irradiâncias e gerar um conjunto de curvas I-V para treinamento (TR).

- b) Definir um valor de irradiância diferente a ser usado nos treinamentos e gerar um conjunto de curvas I-V para teste (T1).
- c) Definir um grupo de painéis fotovoltaicos diferente dos usados no treinamento e gerar um conjunto de curvas I-V para teste (T2).

OBS: Para manter o equilíbrio entre a quantidade de dados de treinamento e teste, se necessário, os dados de testes foram gerados apenas para uma parte das temperaturas utilizadas durante o treinamento.

Etapa 2: Treinamento das amostras:

- a) A separação entre o conjunto de ajuste (80%) e o de validação cruzada (20%) é aleatório e gerada pela biblioteca KERAS no início da operação de treinamento (ajuste de parâmetros da RNC).
- b) Ajustar os hiper parâmetros iniciais e executar o treinamento do modelo com o conjunto de dados de treinamento TR.
- c) A cada época (ciclo de ajuste que passa por todos os dados do conjunto), a perda do conjunto de validação é avaliada e, se houver redução, os pesos são salvos.
- d) Verificar se há convergência entre as curvas de acurácias e perdas, bem como se há viés (baixo valor de acurácia), sobre ajuste (acurácia de ajuste > acurácia de validação) ou sub ajuste (acurácia de ajuste < acurácia de validação).
- e) Calcular as métricas para os conjuntos de treinamento e validação usando os pesos que resultaram no melhor resultado durante o ajuste.
- f) Verificar se o valor dos indicadores F1 Score e AUC estão superiores a 90% e se a perda é inferior a 0.2, valores identificados na literatura como boas referências.
- g) Se necessário, ajustar os hiper parâmetros da RNC, como taxa de aprendizado, tamanho do lote, dimensões da camada conectada e parâmetros de regularização e número de épocas e repetir o treinamento. Retomar ao passo (d).
- h) Salvar o melhor modelo da RNA para a amostra.
- i) Salvar a matriz de confusão e preencher os resultados nos quadros de resumo de resultados.

Etapa 3: Predição das amostras com a base de testes:

- a) Carregar o melhor modelo gerado no treinamento da respectiva amostra.
- b) Carregar a base de teste T1 e executar a predição.
- c) Salvar a matriz de confusão e preencher os resultados nos quadros de resumo de resultados.
- d) Carregar a base de teste T2 e executar a predição.
- e) Salvar a matriz de confusão e preencher os resultados nos quadros de resumo de resultados.

4.3. PREPARAÇÃO DAS FERRAMENTAS COMPUTACIONAIS

Todas as ferramentas foram desenvolvidas em linguagem Python e executadas a partir do ambiente integrado SPYDER ou JUPYTER NOTEBOOK. Maiores detalhes da configuração do ambiente de trabalho no Apêndice A.

4.3.1. Algoritmo para geração de curvas características I-V


As curvas I-V são geradas a partir da simulação do circuito equivalente do diodo único, através de parâmetros elétricos fornecidos pelos fabricantes dos painéis fotovoltaicos utilizados. São geradas a partir de amostras compostas por um grupo de painéis organizados num arranjo homogêneo, um grupo de temperaturas e um grupo de irradiâncias.

Para fim de validação, inicialmente, gerou-se as curvas I-V de um painel em cenários de irradiância normal para diversas temperaturas e as comparou com as curvas de exemplo disponíveis nas fichas técnicas fornecidas pelos fabricantes.

Em seguida, realizou-se a soma de duas ou mais curvas em série e, posteriormente, em paralelo, comparando com o resultado da função da PVLIB que calcula a curva I-V para um arranjo qualquer ($N \times N$).

Na sequência, utilizando o painel e padrões de irradiância (normal e sob sombras) propostos por Bonthagorla e Mikkili (2020), fez-se a geração das curvas para o arranjo com 7 segmentos em paralelo com 7 painéis em série cada (7 x 7), chegando em curvas praticamente idênticas ao indicado no artigo, conforme exemplo da Figura 57. Alguns detalhes adicionais podem ser obtidos no Apêndice B.

Figura 57 – Curvas equivalentes no cenário de sombras parciais.



Fonte: Adaptado de Bonthagorla e Mikkili (2020).

4.3.2. Algoritmo para treinamento de RNC

A partir de um conjunto de parâmetros de entrada que identificam a amostra e definem como a RNC deve ser construída e otimizada ao longo do treinamento, executa-se o algoritmo para treinamento do modelo. Além da escolha de uma das arquiteturas implementadas (LENET-5, ALEXNET, VGG16 e EfficientNET-V2S) é possível escolher parâmetros de regularização L1, L2 e *dropout* para inibir bias e variância entre as bases de treinamento e validação durante o treinamento, conforme exemplo na Figura 58. Detalhes adicionais podem ser obtidos no Apêndice C.

Figura 58 – Exemplo de parâmetros para treinamento.

```

ParametrosAmostra = {
    'Fase'          : "1",
    'Etapa'         : "1",
    'Experimento'    : "1",
    'Amostra'       : "A.4",
    'Iteracao'      : "1",
    'TipoCurva'     : "IV",          # IV / PV
    'NumeroClasses' : 8,
    'PontosCurva'  : 480,          # 500 / 1000 / 2000, conforme simulação das curvas
    'FormatoImagem' : (480,480,1), # resoluções 240, 320, 480, 640, conforme imagens geradas
                                     # profundidade de cor 1 (binarizada) ou 3 (colorida)
    'DiretorioImagens' : "\\Experimentos\\A.4\\TR"
                                     # directory, conforme Keras API, considerando a partir
                                     # do diretório base, com uma pasta por classe
}

ParametrosTreinamento = {
    'NumeroCamadas' : 1,          # número de camadas Dense, conforme Keras API
    'NumeroNeuronios' : 256,      # número de UNITS da camada, conforme Keras API
    'Regularizacao'  : [ 1e-4, 1e-4, 1e-5, 0.3],
                                     # regularizers (L1, L2, dropout), conforme Keras API
    'Otimizacao'     : [ 1e-3, 1 ],
                                     # optimizer ADAM (Learning_rate, AMSgrd ), conforme Keras AP.
    'PercentualValidacao' : 0.2,  # validation_split, conforme Keras API
    'TamanhoLote'     : 32,       # batch_size, conforme Keras API
    'NumeroEpocas'    : 50,       # epochs, conforme Keras API
    'Paciencia'        : 5,       # patience, conforme Keras API
    'ReduzirPrecisao' : "1",      # 0 / 1, aplica otimização da GPU NVIDIA para usar FLOAT16
    'NumeroGPU'        : "1",     # 0 / 1, seleciona GPU NVIDIA do servidor
    'CarregarMelhorPesos' : "0"   # se 1, inicializa com os melhores pesos da mesma iteração
}

# Executa todo o treinamento
from Treinamento_config import Executa_treinamento


Executa_treinamento( ParametrosTreinamento, ParametrosAmostra, "LENET" )

```

Fonte: Elaborado pelo autor.

Após o encerramento do processo de treinamento, seja por atingir o número máximo de épocas configurado ou uma condição de encerramento antecipado, apresenta-se um gráfico com a evolução da perda e acurácia ao longo do treinamento, conforme Figura 59.


Figura 59 – Exemplo de evolução do treinamento.



Fonte: Elaborado pelo autor.

Na sequência é calculado um conjunto de indicadores e mostrada a matriz de confusão e as curvas ROC utilizando a parte da amostra separada para validação, conforme Figura 60.

Figura 60 – Exemplo de matriz de confusão curvas ROC da base de validação.



Fonte: Elaborado pelo autor.

4.3.3. Algoritmo para predição em amostras

A partir da indicação do caminho das imagens que compõem a amostra de teste que se deseja avaliar e o caminho do arquivo salvo com o melhor modelo de RNC treinado, executa-se o algoritmo de predição da respectiva amostra, conforme Figura 61.

Figura 61 – Exemplo de parâmetros para predição.

```
ParametrosAmostra = {
    'Fase'       : "1",
    'Etapa'      : "1",
    'Experimento' : "1",
    'Amostra'    : "A.8.T1",
    'Iteracao'   : "1",
    'TipoCurva'  : "IV",          # IV / PV
    'NumeroClasses' : 12,
    'PontosCurva' : 480,        # 500 / 1000 / 2000, conforme simulação das curvas
    'FormatoImagem' : (480,480,1), # resoluções 240, 320, 480, 640, conforme imagens gerada
                                     # profundidade de cor 1 (binarizada) ou 3 (colorida)
    'DiretorioImagens' : ".\\Experimentos\\A.8\\T1",
                                     # directory, conforme Keras API, considerando a partir
                                     # do diretório base, com uma pasta por classe
    'MelhorModelo' : ".\\Experimentos\\A.8\\TR\\modelo_IV_1_1_A.8_1.h5",
    'ReduzirPrecisao' : "1",      # 0 / 1, aplica otimização da GPU NVIDIA para usar FLOAT16
    'NumeroGPU' : "0",           # 0 / 1, seleciona GPU NVIDIA do servidor
}


# Executa todo o treinamento
from Analise_config import Executa_analise

y, p = Executa_analise( ParametrosAmostra )
```

Fonte: Elaborado pelo autor.

Após processamento os indicadores são calculados e a matriz de confusão e as curvas ROC são geradas, com todas as classes envolvidas, conforme Figura 62.

Figura 62 – Exemplo de matriz de confusão curvas ROC da base de teste.



Fonte: Elaborado pelo autor.

Detalhes adicionais podem ser obtidos no Apêndice D.

5. EXECUÇÃO DOS EXPERIMENTOS

5.1. Fase 1 – Execução do treinamento do modelo com 8 classes

A composição das amostras geradas a partir do modelo com 8 classes já foi detalhada na Seção 4.2.4.1. A Tabela 15 mostra a segregação das imagens em bases de treinamento (ajuste e validação cruzada) e teste.

Tabela 15 – Resumo da segregação de bases – 8 classes

Amostra	Classes	Total de Imagens	Treinamento		Teste	
			Ajuste	Validação	T1 - Novas irradiâncias	T2 - Novos Painéis
A.1	8	10.920	6.240 (57,1%)	1560 (14,3%)	1.560 (*) (14,3%)	1.560 (**) (14,3%)
A.2	8	54.600	31.200 (57,1%)	7.800 (14,3%)	7.800 (*) (14,3%)	7.800 (**) (14,3%)
A.3	8	42.900	24.960 (58,2%)	6.240 (14,5%)	7.800 (18,2%)	3.900 (9,1%)
A.4	8	214.500	124.800 (58,2%)	31.200 (14,5%)	39.000 (18,2%)	19.500 (9,1%)

Fonte: Elaborado pelo autor.

A Tabela 16 mostra o resultado do treinamento e da predição com as bases de validação cruzada e de testes T1 e T2.

Tabela 16 – Resultado do treinamento das amostras – Fase 1

Amostra	Indicadores do Treinamento					Indicadores do Teste				
	Ajuste		Validação		Época Final					
	Acurácia	Perda	Acurácia	Perda		Base de teste	Precisão	Sensibilidade	F1 Score	AUC
A.1	99,09	0,03	97,63	0,06	30	Validação	97,54	97,94	97,74	98,79
	-	-	68,72	1,53	-	T1	72,05	59,48	62,41	77,34
	-	-	99,10	0,03	-	T2	98,76	99,54	99,13	99,71
A.2	97,70	0,06	97,36	0,07	22	Validação	96,67	96,57	96,56	98,09
	-	-	73,54	1,71	-	T1	70,79	66,66	65,43	81,42
	-	-	98,00	0,06	-	T2	96,99	97,66	97,18	98,69
A.3	98,03	0,05	97,47	0,07	16	Validação	97,25	96,88	97,06	98,25
	-	-	90,05	0,49	-	T1	88,33	85,63	86,75	92,08
	-	-	98,59	0,04	-	T2	98,16	98,76	98,43	99,28
A.4	96,25	0,10	96,10	0,11	23	Validação	95,50	94,01	94,55	96,71
	-	-	90,03	0,32	-	T1	88,24	86,09	86,37	92,34
	-	-	96,32	0,10	-	T2	95,27	94,02	94,41	96,74

Fonte: Elaborado pelo autor.


Observa-se que os indicadores AUC e F1 Score tiveram valores significativos durante o treinamento, bem superiores a 90%, logo, o modelo tem excelente capacidade para classificar as curvas-IV e que existe bom equilíbrio entre as classes

definidas.

Porém, ao avaliar a capacidade de generalização do modelo, observa-se um decréscimo significativo dos indicadores na predição dos cenários de testes T1 e T2. Também se observa que na medida que a amostra se torna mais complexa (cenários com maior número de arranjos e irradiâncias) e consequentemente mais amostras, os resultados de treinamento tem pequeno decréscimo, mas os de teste tem uma melhora.

A Figura 63 mostra a matriz de confusão e as curvas ROC para a amostra A.4. Observa-se que os valores mais significativos de falsos positivos e negativos (destacado em vermelho) que aparecem fora do eixo central (destacado em verde), estão concentrados nas classes de mesma condição de irradiância, normal ou sob sombras. Apenas uma classe apresentou valor de AUC abaixo de 0,9 e todas as demais e outras 5 com valores acima de 0,98, demonstrando que existe boa separação entre as classes.

Figura 63 – Matriz de confusão e Curvas ROC – Treinamento - 8 classes.



Fonte: Elaborado pelo autor.

5.2. Fase 2 – Execução do treinamento do modelo com 12 classes

A composição das amostras geradas a partir do modelo com 12 classes já foi detalhada na Seção 4.2.4.2. A Tabela 17 mostra a segregação das imagens em bases de treinamento (ajuste e validação cruzada) e teste.

Tabela 17 – Resumo da segregação de bases – 12 classes

Amostra	Classes	Total de Imagens	Treinamento		Teste	
			Ajuste	Validação	T1 - Novas irradiâncias	T2 - Novos Painéis
A.5	12	27.300	15.600 (57,1%)	3900 (14,3%)	3.900 (*) (14,3%)	3.900 (**) (14,3%)
A.6	12	136.500	78.000 (57,1%)	19.500 (14,3%)	19.500 (*) (14,3%)	19.500 (**) (14,3%)
A.7	12	107.250	62.400 (58,2%)	15.600 (14,5%)	19.500 (18,2%)	9.750 (9,1%)
A.8	12	536.250	312.000 (58,2%)	78.000 (14,5%)	97.500 (18,2%)	48.750 (9,1%)

Fonte: Elaborado pelo autor.

A Tabela 18 mostra o resultado do treinamento e da predição com as bases de validação cruzada e de testes T1 e T2.


Tabela 18 – Resultado do treinamento das amostras – Fase 2

Amostra	Indicadores do Treinamento					Indicadores do Teste				
	Ajuste		Validação		Época Final					
	Acurácia	Perda	Acurácia	Perda		Base de teste	Precisão	Sensibilidade	F1 Score	AUC
A.5	96,48	0,10	94,77	0,16	29	Validação	94,69	94,95	94,78	97,24
	-	-	62,72	2,46	-	T1	63,44	57,44	58,62	77,00
	-	-	93,67	0,18	-	T2	93,31	93,92	93,57	96,67
A.6	92,16	0,21	91,55	0,23	28	Validação	90,83	90,77	90,67	95,00
	-	-	71,64	1,77	-	T1	69,82	65,98	66,79	81,70
	-	-	91,20	0,24	-	T2	90,14	90,61	90,16	94,91
A.7	91,98	0,21	91,77	0,22	17	Validação	91,03	90,66	90,78	94,95
	-	-	86,83	0,37	-	T1	85,91	83,44	84,19	91,12
	-	-	90,83	0,22	-	T2	90,39	89,94	89,93	94,55
A.8	94,95	0,13	94,13	0,14	50	Validação	93,20	93,04	93,09	96,25
	-	-	91,89	0,22	-	T1	90,69	89,45	89,69	94,36
	-	-	92,88	0,18	-	T2	91,63	92,09	91,77	95,72

Fonte: Elaborado pelo autor.

A Figura 64 mostra a matriz de confusão e as curvas ROC para a amostra A.8. Observa-se que os valores mais significativos de falsos positivos e negativos (destacado em vermelho) que aparecem fora do eixo central (destacado em verde), estão concentrados nas classes de mesma condição de irradiância, normal ou sob sombras. Todas as classes apresentaram valor de AUC acima de 0,9, sendo a maior parte (7), acima de 0,97.


Figura 64 – Matriz de confusão e Curvas ROC – Treinamento 12 classes.



Fonte: Elaborado pelo autor.

Ao avaliar a capacidade de generalização do modelo, observa-se um decréscimo significativo dos indicadores na predição dos cenários de testes T1 e T2. Também se observa que na medida que a amostra se torna mais complexa (cenários com maior número de arranjos e irradiâncias) a tendência dos indicadores se inverte e os valores de AUC e F1 Score tem um incremento tanto no treinamento quanto no teste. A Figura 65 mostra a evolução do treinamento ao longo de todas as amostras.


Figura 65 – Evolução do treinamento para os modelos com 8 e 12 classes.



Fonte: Elaborado pelo autor.

A Figura 66 mostra as curvas ROC para as predições realizadas com as bases de testes T1 e T2, confirmando um bom resultado para cada classe, com a ampla maioria apresentando valores de AUC acima de 0.9.

Figura 66 – Matriz de confusão e Curvas ROC – Testes - 12 classes.



Fonte: Elaborado pelo autor.

Em função desse resultado, considerou-se continuar a pesquisa apenas com o modelo de 12 classes, visto que apesar da maior complexidade, apresentou desempenho equivalente ao modelo de 8 classes oferecendo melhor granularidade da identificação de eventuais perdas ou falhas na operação dos arranjos de painéis fotovoltaicos.

Também decidiu-se incrementar a quantidade de imagens nas amostras a fim de incrementar ainda mais a precisão do classificador, sem alterar as configurações dos cenários (arranjos ou grupos de temperaturas e irradiâncias).

5.3. Fase 3 – Otimização do treinamento do melhor modelo

A Tabela 19 mostra o resultado do treinamento e da predição com as bases de validação cruzada e de testes T1 e T2 para a amostra A.8, cuja composição já foi detalhada nas Seções 4.2.4.2 e 5.2, utilizando diferentes arquiteturas de RNC.

O objetivo desse experimento foi identificar o uso de uma camada convolucional mais extensa, aprimorar a captura de características e, conseqüentemente, os indicadores da classificação, AUC e F1 Score.


Em função das diferentes características das RNC, as imagens foram convertidas para a resolução 224x224 durante o carregamento pelo modelo, correspondente ao requisito da arquitetura VGG16, menor entre todas as utilizadas.

Tabela 19 – Comparação do treinamento – Diferentes arquiteturas RNC

Amostra	Indicadores do Treinamento					Indicadores do Teste				
	Ajuste		Validação		Época Final (Tempo)	Base de teste	Precisão	Sensibilidade	F1 Score	AUC
	Acurácia	Perda	Acurácia	Perda						
A.8	98,51	0,04	97,15	0,07	50	Validação	96,71	96,72	96,70	98,23
LENET-5	-	-	94,11	0,25	05:50h	T1	93,55	92,35	92,54	95,91
	-	-	94,69	0,14		T2	93,63	93,77	93,69	96,65
A.8	98,57	0,04	97,61	0,06	20	Validação	97,21	97,09	97,14	98,44
ALEXNET	-	-	95,47	0,18	02:49h	T1	94,80	94,08	94,12	96,84
	-	-	96,01	0,12		T2	95,15	95,59	95,32	97,61
A.8	99,03	0,03	98,16	0,05	36	Validação	97,78	97,93	97,85	98,88
VGG16	-	-	95,88	0,32	21:30h	T1	95,43	94,82	94,74	97,23
	-	-	94,99	0,18		T2	93,94	94,61	94,19	97,08
A.8	98,07	0,05	97,45	0,06	11	Validação	96,99	96,98	96,96	98,38
EFFICIENT_	-	-	95,27	0,16	07:47	T1	94,43	93,85	93,86	96,71
	-	-	96,25	0,09		T2	95,32	95,74	95,49	97,70

Fonte: Elaborado pelo autor.

Os resultados obtidos com as diversas arquiteturas foram muito parecidos, conforme pode ser observado na Figura 67.



Fonte: Elaborado pelo autor.

Enquanto a VGG16 teve melhor desempenho no treinamento, a ALEXNET e a EfficientNet tiveram melhor resultado na fase de testes, o que as torna mais interessantes, visto que um dos objetivos da pesquisa é obter um classificador com maior capacidade de generalização. Como a arquitetura ALEXNET atingiu o mesmo resultado que a EfficientNet em tempo inferior (2:49 [h], contra 7:47 [h]), optou-se por seguir a pesquisa apenas com essa arquitetura.

A composição das amostras geradas nesta fase já foi detalhada na Seção 4.2.4.3. A Tabela 20 mostra a segregação das imagens em bases de treinamento (ajuste e validação cruzada) e teste.

Tabela 20 – Resumo da composição final das amostras geradas – 12 classes

Amostra	Classes	Total de Imagens	Treinamento		Teste	
			Ajuste	Validação	T1 - Novas irradiâncias	T2 - Novos Painéis
A.9	12	273.000	156.000 (57,1%)	39.000 (14,3%)	48.750 (17,9%)	29.250 (10,7%)
A.10	12	1.364.000	780.000 (57,1%)	195.000 (14,3%)	243.750 (17,9%)	146.250 (10,7%)

Fonte: Elaborado pelo autor.

A Tabela 21 mostra o resultado do treinamento e da predição com as bases de validação cruzada e de testes T1 e T2.

A fim de avaliar o impacto do redimensionamento das imagens para a resolução 224x224, a amostra A.10 também foi treinada na resolução original 480x480, quando apresentou ligeiro ganho nos diversos indicadores avaliados.

Tabela 21 – Resultado do treinamento das amostras – Fase 3


Amostra	Indicadores do Treinamento					Indicadores do Teste				
	Ajuste		Validação		Época Final					
	Acurácia	Perda	Acurácia	Perda		Base de teste	Precisão	Sensibilidade	F1 Score	AUC
A.9	99,16	0,02	98,09	0,05	19	Validação	97,88	97,76	97,81	98,79
224x224	-	-	96,09	0,21	-	T1	95,28	95,01	94,91	97,33
	-	-	94,27	0,21	-	T2	93,99	93,76	93,85	96,62
A.10	99,44	0,02	97,89	0,06	40	Validação	97,70	97,45	97,56	98,63
224x224	-	-	94,39	0,31	-	T1	93,72	92,78	92,75	96,14
	-	-	91,62	0,31	-	T2	91,56	89,68	90,33	94,46
A.10	99,95	0,01	98,12	0,05	50	Validação	97,91	97,86	97,87	98,84
480x480	-	-	94,66	0,28	-	T1	93,99	93,20	93,11	96,36
	-	-	92,76	0,26	-	T2	92,75	90,97	91,63	95,16

Fonte: Elaborado pelo autor.

6. RESULTADOS E DISCUSSÕES


Em função de um dos objetivos propostos ser a construção do modelo computacional com boa capacidade de generalização, a avaliação dos modelos e amostras treinadas se concentrou principalmente na capacidade de predição sobre bases de testes compostas por curvas I-V geradas com modelos de painéis fotovoltaicos e irradiâncias que não fizeram parte da base de treinamento.

A Figura 68 mostra a evolução da predição da Fase 1 na medida que as amostras ficaram maiores e mais complexas, apontando um incremento nos indicadores de avaliação.



Fonte: Elaborado pelo autor.


A Figura 69 mostra a mesma a capacidade de generalização do modelo ao se organizar os painéis em diferentes arranjos e ampliar a quantidade de irradiâncias nos cenários usados para a geração das amostras.



Fonte: Elaborado pelo autor.


Na Figura 70 observa-se que a utilização das imagens com a resolução original 480x480 pixels trouxe um pequeno incremento no resultado, em torno de 1% em cada indicador. Evitar a redução da dimensão das imagens, inibe a introdução de pequenas perdas de detalhes, devido a interpolação necessária para completar as curvas, porém, não é o uso do modelo de RNC

Figura 70 – Comparação da predição por resolução – média de T1 e T2




As Figuras 71 e 72 mostram a matriz de confusão e as curvas ROC para melhor amostra do treinamento e predição, amostra A.10, treinada com a resolução original das imagens, 480x480 pixels.

Figura 71 – Matriz de Confusão e Curvas ROC do melhor treinamento.



Percebe-se que os valores mais significativos de falsos positivos e negativos (destacado em vermelho) que aparecem fora do eixo central (destacado em verde), estão concentrados nas classes de mesma condição de irradiância, normal ou sob sombras. Após treinamento e criação do modelo de RNC, todas as classes apresentaram AUC superior a .99.

Figura 72 – Matriz de Confusão e Curvas ROC da predição combinada T1/T2.



Fonte: Elaborado pelo autor.

Após a predição com uma base de testes com milhares de imagens geradas a partir de painéis fotovoltaicos e irradiâncias diferentes das usadas na geração da base de treinamento, observa-se 9 das 12 classes com AUC superior a 0,96, o que demonstra que o modelo tem boa capacidade de generalização.

7. CONCLUSÕES

A partir dos experimentos executados e das discussões apresentadas, considera-se que os objetivos principal e secundários foram atingidos:

- a) Desenvolvimento de um modelo computacional utilizando RNC para identificação e classificação de condições anormais de operação de arranjos de painéis fotovoltaicos, através de suas curvas I-V, com um total de 12 classes, considerando uma combinação entre as condições de irradiância normal e sob sombras e as anomalias de mismatch, curto-circuito e circuito aberto, a saber: Normal, *Mismatch_normal*, *CA_normal*, *CC_normal*, *Mismatch_normal_CC*, *Mismatch_normal_CA*, Sombras, *Mismatch_sombras*, *CA_sombras*, *CC_sombras*, *Mismatch_sombras_CC*, *Mismatch_sombras_CA*;
- b) Geração e disponibilização de uma base de imagens normalizadas de curvas I-V envolvendo 30 painéis fotovoltaicos, configurados em 5 arranjos, com 20 irradiâncias e 10 temperaturas, num total de 1.364.000 imagens, na resolução 480x480 píxeis;
- c) Treinamento, otimização e disponibilização de um modelo de RNC, baseado na arquitetura ALEXNET, com boa capacidade de generalização para ser utilizado na predição de curvas I-V geradas em outros cenários operacionais (temperatura, irradiância, arranjos). O modelo foi validado dentro das seguintes condições:
 - Faixa de temperaturas: 5 a 75 [°C].
 - Faixa de irradiâncias: 200 a 1150 [W/m²].
 - Arranjos nas configurações: 7x7, 6x8, 5x9, 4x12, 3x16.
 - Painéis com potências entre 200 e 650 [W] de diversos fabricantes, mono ou bifacial, material mono ou policristalino,
 - Imagens com resolução máxima de 480x480 reduzidas até 224x224.

8. CONSIDERAÇÕES FINAIS E CONTRIBUIÇÕES DO ESTUDO

Especificamente na geração de energia elétrica através de fontes renováveis, em destaque a energia solar aqui abordada, o uso desse ferramental computacional contribui com o aprimoramento da confiabilidade e da eficiência energética dos sistemas elétricos, resultando em ganhos diretos para a sociedade com a redução de custos de implantação e operação, bem como um aumento da vida útil dos equipamentos e aumento da energia total produzida.

Considera-se que a pesquisa também contribuiu nas áreas da Tecnologia da Informação e Engenharia Elétrica, podendo seus resultados serem submetidos futuramente em revistas ou congressos:

- a) Contribuições a partir da aplicação prática envolvendo modelagem e simulação de geração de energia solar usando a biblioteca PVLIB Python;
- b) Resultados alcançados e contribuições na aplicação de técnicas de aprendizado de máquina para simulação e identificação de falhas em SFV utilizando redes neurais convolucionais.

9. TRABALHOS FUTUROS E APRIMORAMENTOS

Em função de toda a pesquisa realizada, das premissas estabelecidas para o desenvolvimento do tema, das limitações identificadas e dos resultados alcançados, identifica-se um conjunto de aprimoramentos que podem ser executados, com o objetivo de aprimorar os resultados no futuro, entre eles:

- a) Inclusão de maior número de painéis fotovoltaicos e arranjos a fim de ampliar a capacidade de generalização do modelo de RNC;
- b) Inclusão de maior número de irradiâncias e temperaturas a fim de ampliar a capacidade de generalização do modelo de RNC;
- c) Validação do modelo de RNC com outras arquiteturas de RNC mais complexas e que dependerão de maior capacidade computacional;
- d) Avaliar o uso de outras técnicas de balanceamento das classes, a fim de melhorar o resultado para as classes que apresentaram desempenho inferior durante os testes de generalização da RNC;
- e) Avaliar um modelo matemático do circuito equivalente dos arranjos considerando conexões diferente de série-paralelo entre os painéis e a presença de elementos de proteção como os diodos *by-pass* e de bloqueio.

REFERÊNCIAS

ABSOLAR. **Energia Solar Fotovoltaica no Brasil. Infográfico.** ABSOLAR. 2024. Disponível em: <https://www.absolar.org.br/mercado/infografico/>. Acesso em 18 jan. 2024.

ANDREW, N. **Structuring Machine Learning Projects**. 2018. COURSERA. Disponível em: <https://www.coursera.org/learn/machine-learning-projects>. Acesso em 01 out. 2023.

ANEEL. **Sistema de Informações de Geração da ANEEL – SIGA**. Matriz Elétrica Brasileira. 2024. Disponível em: <https://app.powerbi.com/view?r=eyJrljoiNjc4OGYyYjQtYWM2ZC00YjllLWJlYmEtYzdkNTQ1MTc1NjM2liwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOjR9>. Acesso em 18 jan. 2024.

ANEEL. **Resolução Normativa nº 482, de 17 de abril de 2012**. Disponível em: <https://www2.aneel.gov.br/cedoc/ren2012482.pdf>. Acesso em: 12 nov. 2022.

ANEEL. **Resolução Normativa nº 687, de 24 de novembro de 2015**. Disponível em: <https://www2.aneel.gov.br/cedoc/ren2015687.pdf>. Acesso em: 12 nov. 2022.

ASSEMBLÉIA GERAL. Nações Unidas (org.). A/RES/70/1 **Transforming our world: the 2030 Agenda for Sustainable Development**. 2015. GENERAL ASSEMBLY. 21 out. 2015.

BISHOP, J. W (1988). **Computer simulation of the effects of electrical mismatches in photovoltaic cell interconnection circuits**. , 25(1), 73–89. doi:10.1016/0379-6787(88)90059-2 .

BISOL. Catalogs > BISOL > **Monocrystalline PV Modules Datasheet**. 2022. Disponível em: <https://pdf.archiexpo.com/pdf/bisol/monocrystalline-pv-modules-datasheet/66976-63743.html>. Acesso em: 6 nov. 2022.

BONTHAGORLA, P. K., & MIKKILI, S. (2020). **Performance analysis of PV array configurations (SP , BL , HC and TT) to enhance maximum power under non-uniform shading conditions**. *Engineering Reports*. WILEY; 2020;2:e12214. doi:10.1002/eng2.12214.

BOUREAU, Y.L.; PONCE, J.; LECUN, Y. **A theoretical analysis of feature pooling in visual recognition**. 27th International Conference on Machine Learning, HAIFA, ISRAEL. [S.l.: s.n.], 2010.

CANADIANSOLAR, **DATASHEET CS3W-395**. 2023. Disponível em: <https://cdn.enfsolar.com/z/pp/qoa60dd3514b8d9a/5fe019439aa9d.pdf> Acesso em: 01 out. 2023.

CAPES. **Portal de Periódicos da CAPES**. 2023. Disponível em: <https://www-periodicos-capes-gov-br.ez345.periodicos.capes.gov.br/> Acesso em: 01 out. 2023.

CAPES. **Guia do Portal de Periódicos da CAPES**. 2019. Disponível em: https://www.periodicos.capes.gov.br/images/documents/Portal_Peri%C3%B3dicos_CAPES_Guia_2019_4_oficial.pdf Acesso em: 01 out. 2023.

CASALS-TORRENS, P. **Virtual Laboratory for Learning Asynchronous Motors in Engineering Degrees**. IEEE Journal of Latin American Learning Technologies, Volume 8, No. 2, Maio 2013.

CHEN, Z.; WU, L.; CHENG, S.; LIN, P.; WU, Y.; LIN, W. **Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and I-V characteristics**. Appl. Energy 2017, 204, 912–931.

CHEN, Z., YU, H., LUO, L., WU, L., ZHENG, Q., WU, Z., LIN, P. **Rapid and accurate modeling of PV modules based on extreme learning machine and large datasets of I-V curves**. 2021, Applied Energy, 292, 116929. doi:10.1016/j.apenergy.2021.116929

CHUNG, C. A. **Simulation Modeling Handbook: A Practical Approach**. 2004. CRC Press.

CRESWELL, J. W. **Projeto de Pesquisa: métodos quantitativo, qualitativo e misto**. 5ª Edição, Porto Alegre, Editora Penso, 2021.

ENERGES. **Entenda as Principais Degradações dos Módulos Fotovoltaicos**. ENERGES. 2022. Disponível em: <https://energes.com.br/entenda-as-principais-degradacoes-dos-modulos-fotovoltaicos/>. Acesso em: 18 jan. 2024.

ELSEVIER, **SCOPUS**. 2024. Disponível em: <https://www-scopus.ez345.periodicos.capes.gov.br/search/form.uri?display=basic&zone=header&origin=#basic>. Acesso em 18 jan. 2024.

ELSEVIER, ***What does "Relevance" mean in Scopus? - Scopus: Access and use Support Center (elsevier.com)***, 2023. Disponível em: https://service.elsevier.com/app/answers/detail/a_id/14182/supporthub/scopus/#. Acesso em 01 out. 2023.

ELSEVIER. ***How are CiteScore metrics used in Scopus?***, 2023. Disponível em: https://service.elsevier.com/app/answers/detail/a_id/14880/supporthub/scopus/. Acesso em 01 out. 2023.

GÉRON, A. ***Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems***. O'Reilly Media, Inc., 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>. Acesso em 01 out. 2023.

GIL, A. C. **Como elaborar projetos de pesquisa**, 4ª Edição, Editora Atlas, São Paulo, 2002.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**, 3ª Edição, São Paulo : Pearson Prentice Hall, 2010.

GURUPIRA, T, Rix, A (2017). ***Pv simulation software comparisons: Pvsyst, nrel sam and pvlib***. SAUPEC, Disponível em: orcid.org/0000-0001-9145-1000.

HANSEN, C. W. **Parameter Estimation for Single Diode Models of Photovoltaic Modules**. SANDIA REPORT. SAND2015-2065. [S. L.]: SANDIA, mar. 2015.

HAY, J. E., Davies, J. A., 1980. ***Calculation of the solar radiation incident on an inclined surface***. *First Canadian Solar Radiation Data Workshop* (Eds: JE Hay and TK Won), Ministry of Supply and Services Canada, vol. 59.

HOLMGREN, W. F.; ANDREWS, R. W.; LORENZO, A. T.; STEIN, J. S. **PVLIB Python 2015**. 2015 IEEE 42Nd Photovoltaic Specialist Conference (Pvsc), [S.L.], jun. 2015. IEEE. <http://dx.doi.org/10.1109/pvsc.2015.7356005>.

HOLMGREN, W. F.; GROENENDYK, D. G. ***An open source solar power forecasting tool using PVLIB-Python***. 2016 IEEE 43Rd Photovoltaic Specialists Conference (Pvsc), [S.L.], jun. 2016. IEEE. <http://dx.doi.org/10.1109/pvsc.2016.7749755>.

HOLMGREN, W. F.; HANSEN, C. W.; STEIN, J. S.; MIKOFSKI, M. A. ***Review of Open Source Tools for PV Modeling***. 2018 IEEE 7Th World Conference On Photovoltaic Energy Conversion (Wcpec) (A Joint Conference Of 45Th IEEE Pvsc, 28Th Pvsec & 34Th Eu Pvsec), [S.L.], jun. 2018. IEEE. <http://dx.doi.org/10.1109/pvsc.2018.8548231>.

HOLMGREN, W. F.; HANSEN, C. W.; MIKOFSKI, M. A. ***Pvlib python: a python package for modeling solar energy systems***. *Journal Of Open Source Software*, [S.L.], v. 3, n. 29, p. 884, 7 set. 2018. The Open Journal. <http://dx.doi.org/10.21105/joss.00884>.

HONSBURG, C. B.; BOWDEN, S. G. **Photovoltaics Education Website**. 2019. Disponível em:

<https://www.pveducation.org/pvcdrom/modules-and-arrays/module-circuit-design>. Acesso em: 25 nov. 2022.

HUANG, J.; WAI, R. J., GAO, W.. **Newly-Designed Fault Diagnostic Method for Solar Photovoltaic Generation System Based on IV-Curve Measurement**. 2019, IEEE Access, 1–1. Disponível em: doi:10.1109/access.2019.2919337

HUBEL, D. H.; WIESEL, T. N. **Receptive fields and functional architecture of monkey striate cortex**. *The Journal of Physiology*, v. 195, n. 1, p. 215–243, 1968. ISSN 0022-3751. Disponível em: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1557912/>.

INTELBRAS, **EMSB-535M HC**. 2023. Disponível em: <https://backend.intelbras.com/sites/default/files/2022-03/Datasheet EMSB 535M HC R7 1.pdf> Acesso em: 01 out. 2023.

INTELBRAS, **EMSB-455 HC**. 2023. Disponível em: <https://backend.intelbras.com/sites/default/files/2023-04/datasheet-emsb-455-hc-pt.pdf>. Acesso em: 01 out. 2023.

JAIN, A. **Exact analytical solutions of the parameters of real solar cells using Lambert W-function**. *Solar Energy Materials And Solar Cells*, [S.L.], v. 81, n. 2, p. 269–277, 6 fev. 2004. Elsevier BV. <http://dx.doi.org/10.1016/j.solmat.2003.11.018>.

KARPATHY, A. et al. **Cs231n: Convolutional Neural Networks for Visual Recognition**. *Neural networks*, Stanford, 2016. Disponível em: <http://cs231n.github.io/convolutional-networks/>.

KIM, G. G., Lee, W., Bhang, B. G., Choi, J. H., & Ahn, H.-K. (2021). **Fault Detection for Photovoltaic Systems Using Multivariate Analysis With Electrical and Environmental Variables**. *IEEE Journal of Photovoltaics*, 11(1), 202–212. doi:10.1109/jphotov.2020.3032974.

KLETTLE, R. **Concise Computer Vision**. Undergraduate Topics in Computer Science. Ed. SPRINGER, 2014, doi:10.1007/978-1-4471-6320-6.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey. **ImageNet classification with deep convolutional neural networks**. *Communications of the ACM*. v. 60. n. 6. maio 2017. ELSEVIER, 2023.

KYOCERA. **KC200GT**. 2023. Disponível em: <https://www.energymatters.com.au/images/kyocera/KC200GT.pdf>. Energy Matters. Acesso em: 01 out. 2023.

LAW, A. M. **Simulation Modeling and Analysis**. 2014. 5ª Edição, McGraw Hill

LECUN, Y. et al. **Gradient-based learning applied to document recognition**. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2323, 1998. ISSN 00189219.

LOUTZENHISER, P. G. et al. (2007). **Empirical validation of models to compute solar irradiance on inclined surfaces for building energy simulation**. *Solar Energy*, 81(2), 254–267. doi:10.1016/j.solener.2006.03.009.

MARCONI, M. A. **Fundamentos de metodologia científica** / MARCONI, M. A , LAKATOS, E. M. Atualização da edição de João Bosco Medeiros, 9ª edição, São Paulo, Editora Atlas, 2021.

MCCULLOCH, W. S.; PITTS, W.: **A logical calculus of the ideas immanent in nervous activity**. *The bulletin of mathematical biophysics*, Vol 5 (4): pp. 115-133, 1943.

MITCHELL, T. M.: **Machine Learning**. McGraw-Hill, Inc., USA, 1ª edição, 1997, ISBN 978-0-07-042807-2.

MOL, A. A., Martins F., L. S., Silva, J. D. S.; Rocha, R. **Efficiency parameters estimation in gemstones cut design using artificial neural networks**. Computational materials science, 38(4):727–736, 2007. viii, 12.

MORAIS, C. **Uma introdução aos sistemas fotovoltaicos**. ELETRONICA DE POTENCIA. 2024. Disponível em: <https://eletronicadepotencia.com/sistemas-fotovoltaicos>. Acesso em: 18 jan. 2024.

MPPT SOLAR. **Painéis solares: Ligação em paralelo**. 2024. Disponível em: <https://www.mpptsolar.com/pt/paineis-solares-em-paralelo.html>. Acesso em: 18 jan. 2024.

NREL. **NSRDB: National Solar Radiation Database. International Data**. 2022. Disponível em: <https://nsrdb.nrel.gov/data-sets/international-data>. Acesso em: 25 nov. 2022.

OTSU N. **A threshold selection method from gray-level histograms**. IEEE Transactions on Systems, Man, and Cybernetics. 1979; 9(1):62-66. <http://dx.doi.org/10.1109/TSMC.1979.4310076>.

PACTO GLOBAL REDE BRASIL. Nações Unidas (org.). **ESG. Entenda o significado da sigla ESG (Ambiental, Social e Governança) e saiba como inserir esses princípios no dia a dia de sua empresa**. Pacto Global Rede Brasil, 2022. Disponível em: <https://www.pactoglobal.org.br/pg/esg>. Acesso em: 12 nov. 2022.

PEREIRA, E. *et al.* Atlas brasileiro de energia solar. **Atlas Brasileiro de Energia Solar**, [S.L.], 2017. Universidade Federal de São Paulo. <http://dx.doi.org/10.34024/978851700089>.

PEREZ, R. *et al.* (1987). **A new simplified version of the perez diffuse irradiance model for tilted surfaces**. Solar Energy, 39(3), 221–231. doi:10.1016/s0038-092x(87)80031-2.

PORTAL SOLAR. **Usina Solar: o que é, tipos, como funciona, vantagens e desvantagens**. 2024. Disponível em: <https://www.portalsolar.com.br/usina-solar.html>. Acesso em: 18 jan. 2024.

PORTAL SOLAR. **Célula fotovoltaica: tudo o que você precisa saber**. 2024. Disponível em: <https://www.portalsolar.com.br/celula-fotovoltaica.html>. Acesso em: 18 jan. 2024.

PORTAL SOLAR. **Painel solar: o que é, como funciona e tipos**. 2024. Disponível em: <https://www.portalsolar.com.br/painel-solar>. Acesso em: 18 jan. 2024.

PVLIB PYTHON DEVELOPMENT TEAM. **PVLIB: what's new pvlib python 0.9.3**. 2021. Disponível em: <https://pvlib-python.readthedocs.io/en/v0.9.3/whatsnew.html>. Acesso em: 6 nov. 2022.

RUMELHART, D.; HINTON, G.; WILLIAMS, R.. **Learning Internal Representations by Error Propagation**. Institute for Cognitive Science, University of California, San Diego, 1985.

SANDIA. **PV performance Modeling Collaborative**: modeling steps. 2018. Disponível em: <https://pvpmc.sandia.gov/modeling-steps>. Acesso em: 06 nov. 2022.

SANDIA. **Photovoltaic Solar Energy**: sandia has been performing photovoltaic r&d for over 40 years. 2022. Disponível em: <https://energy.sandia.gov/programs/renewable-energy/photovoltaic-solar-energy>. Acesso em: 6 nov. 2022.

SARIKH, S., Raoufi, M., Bennouna, A., Benlarabi, A., & Ikken, B. **Photovoltaic system fault identification methodology based on I-V characteristics analysis**. XI AMEN-CUSTIPEN Workshop on the equation of state of dense neutron-rich matter in the era of gravitational wave astronomy. 2019. doi:10.1063/1.511696.

SIMONYAN, K., & ZISSERMAN, A. **Very Deep Convolutional Networks for Large-Scale Image Recognition**. ICLR 2015. 2014. Disponível em: <https://arxiv.org/abs/1409.1556>.

SOTO, W.; KLEIN, S.A.; BECKMAN, W.A. **Improvement and validation of a model for photovoltaic array performance**. Solar Energy, [S.L.], v. 80, n. 1, p. 78-88, jan. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.solener.2005.06.010>.

SOUZA, J. P. **Módulos Fotovoltaicos - Perdas por Mismatch em Sistemas Fotovoltaicos**. ECORI 2019. Disponível em: <https://www.ecorienergiasolar.com.br/artigo/modulos-fotovoltaicos---perdas-por-mismatch-em-sistemas-fotovoltaicos>. Acesso em: 18 jan. 2024.

SPATARU, S.; SERA, D.; KEREKES, T.; TEODORESCU, R., **Diagnostic method for photovoltaic systems based on light I-V measurements**, Sol. Energy, vol. 119, pp. 29–44, Sep. 2015.

STEIN, J. S. **The photovoltaic Performance Modeling Collaborative (PVPMC)**. 2012 38Th IEEE Photovoltaic Specialists Conference, [S.L.], jun. 2012. IEEE. Disponível em: <http://dx.doi.org/10.1109/pvsc.2012.6318225>.

STEIN, J. S. *et al.* **PVLIB: open source photovoltaic performance modeling functions for matlab and python**. 2016 IEEE 43Rd Photovoltaic Specialists Conference (Pvsc), [S.L.], jun. 2016. IEEE. <http://dx.doi.org/10.1109/pvsc.2016.7750303>.

TAN, M., LE, Q. V. **EfficientNetV2: Smaller Models and Faster Training**. ICML 2021. 2021. Disponível em: <https://arxiv.org/abs/2104.00298>.

TIAN, H.; MANCILLA-DAVID, Fernando; ELLIS, Kevin; MULJADI, Eduard; JENKINS, Peter. **A cell-to-module-to-array detailed model for photovoltaic panels**. Solar Energy, [S.L.], v. 86, n. 9, p. 2695-2706, set. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.solener.2012.06.004>.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. **How transferable are features in deep neural networks?** 2014. Advances in neural information processing systems, 27, p. 3320-3328. Disponível em: [10.48550/arxiv.1411.1792](https://arxiv.org/abs/1411.1792).

WANG, T.; WU, D. J.; COATES, A.; NG, A. Y. **End-to-end text recognition with convolutional neural networks**. Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012). 2012. p. 3304–3308.

APÊNDICE A – AMBIENTE COMPUTACIONAL UTILIZADO

A) Equipamentos utilizados

Equipamento	Função	Configuração
NOTEBOOK	Desenvolvimento dos programas e execução de validações	I7-8ª geração, 3,6 GHz, 16 GB RAM, GPU 4 GB
SERVIDOR 1	Geração das amostras de curvas características para experimentos	I7-8ª geração, 3,6 GHz, 16 GB RAM, GPU 4 GB
SERVIDOR 2	Execução de treinamento das RNC e predição a partir das amostras geradas	R7, 3,6 GHz, 64 GB RAM, 2 x GPU GeForce 3040 12 GB

B) Versão do Python e de suas bibliotecas

Ferramenta	Versão	Função	Caminho de instalação / Site de suporte
Python	3.10	Linguagem de programação	https://www.python.org/downloads/
Matplotlib	4.x	Biblioteca para traçar gráficos e salvar imagens	https://matplotlib.org/stable/users/installing/index.html
PVLIB	0.10.3	Biblioteca para simulação de SFV	https://pvlb-python.readthedocs.io/en/stable/
TensorFlow / Keras	2.10	Biblioteca para treinamento de RNC	https://pypi.org/project/tensorflow-gpu/2.10.0/

C) Ferramentas de apoio

Ferramenta	Versão	Função	Caminho de instalação / Site de suporte
Jupyter notebook	3.10	Ambiente para execução de programas Python a partir de um navegador WEB	https://jupyter.org/
Spyder	5.0	Ambiente integrado para desenvolvimento, depuração e execução de programas em Python	https://spyder.org

APÊNDICE B – PROGRAMA PARA GERAÇÃO DE CURVAS I-V

Abaixo seguem detalhes do código do programa de geração das curvas I-V.

A Figura 73 mostra o início do processo com a definição dos parâmetros que serão usados para a geração de toda uma amostra.

Figura 73. – Configuração dos parâmetros para geração de uma amostra.

```
# Parâmetros de entrada
PNG = 0          # 0=JPG, 1=PNG
QUALID = 1       # 0=Padrão, 1=Aprimoramento
Strings = 7       # Número de strings em paralelo
Modulos = 7       # Número de painéis em série por string
Pontos = 2000     # Quantidade de pontos para simulação das curvas IV/PV
Cor = 0          # 0=Binarizada, 1=RGB
TipoCurva = 'IV'  # 'IV' ou 'PV'
Resolucao = 320   # Resolução em pixels, idênticas para horizontal e vertical
Amostra = '320-7x7-5P-10TI' # Nome da pasta onde a amostra será gravada
...

...
# Gera uma amostra completa
gera_condicao( Amostra, Resolucao, Resolucao, TipoCurva, Cor )
...
```

Fonte: Elaborado pelo autor.

A Figura 74 mostra a chamada de processamento para um painel fotovoltaico a partir dos parâmetros extraídos do catálogo do fabricante, incluindo a chamada da geração para cada uma das condições operacionais.

Figura 74 – Execução do processamento para um painel.

```
# Gera as curvas de um painel em todos os cenários
...
#Parâmetros extraídos do manual do painel fotovoltaico
Painel =
{
  'Modelo' : 'KC200GT',
  'Tipo' : 'multiSi',
  'Potencia': 200,
  'Eficiencia': 0,
  'N_s' : 54,
  'I_sc_ref': 8.21,
  'V_oc_ref': 32.9,
  'I_mp_ref': 7.61,
  'V_mp_ref': 26.3,
  'alpha_sc': 0.00318,
  'beta_oc': -0.123,
  'gamma-mp': -0.38
}
...
gera_analise( Painel, Strings, Modulos, Pontos )

...
# Gera cenários
gera_normal( Painel, Strings, Modulos, Pontos )
gera_sombreamento( Painel, Strings, Modulos, Pontos )
gera_curto_circuito( Painel, Strings, Modulos, Pontos )
gera_circuito_aberto( Painel, Strings, Modulos, Pontos )
gera_mismatch( Painel, Strings, Modulos, Pontos )
...
```

Fonte: Elaborado pelo autor.

Dentro de cada condição operacional existe dezenas de cenários. A Figura 75 mostra a chamada de processamento de um cenário na condição operacional sob sombras, para um padrão de sombras específico.

Figura 75 – Execução do processamento para um cenário.

```
...
IdentificadorCenario = 'S4'          # Identificador do cenário para formar o nome do arquivo
...
Temperaturas = [ 5, 25, 45, 55, 70 ]
...
# Sombra lado direito
PadraoSombra = [
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (200, 25), (200, 25), (200, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (300, 25), (300, 25), (300, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (400, 25), (400, 25), (400, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (500, 25), (500, 25), (500, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (600, 25), (600, 25), (600, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (700, 25), (700, 25), (700, 25),
    (1000, 25), (1000, 25), (1000, 25), (1000, 25), (800, 25), (800, 25), (800, 25)
],
...
for T in Temperaturas:
    c2, d2 = calcula_case_sp( Pannel, IdentificadorCenario, PadraoSombra, T, Strings, Modulos, Pontos, 0, 0, 0, 0, 0 )
    salvar_arquivo( '\\sombas\\', d2, c2, Pontos )
```

Fonte: Elaborado pelo autor.

Em cada cenário, para cada condição, os parâmetros do circuito equivalente são calculados e ajustados em relação à irradiância e temperatura que o painel está submetido, para posterior geração da curva I-V, conforme Figura 76.

Figura 76 – Geração da curva I-V pelo método do diodo único.

```
...
#Calcula os parâmetros do circuito do diodo único
I_L_ref, I_o_ref, R_s_ref, R_sh_ref, a_ref, Adjust = ivtools.sdm.fit_cec_sam(parameters['Tipo'], parameters['V_mp_ref'], parameters['I_mp_ref'],
parameters['V_oc_ref'], parameters['I_sc_ref'], parameters['alpha_sc'],
parameters['beta_oc'], gamma_pmp, parameters['N_s'] )
...
#Ajusta parâmetros de acordo com G e T e EgRef
IL, IO, Rs, Rsh, nNsVth = pvsystem.calcpams_desoto( G, T, alpha_sc=parameters['alpha_sc'], a_ref=a_ref, I_L_ref=I_L_ref, I_o_ref=I_o_ref,
R_sh_ref = R_sh_ref, R_s = R_s_ref )
...
#Gera curva IV
curve_info = pvsystem.singlediode( photocurrent=IL, saturation_current=IO, resistance_series=Rs,
resistance_shunt=Rsh, nNsVth=nNsVth, ivcurve_pnts=N, method='Lambertw' )
...
```

Fonte: Elaborado pelo autor.

APÊNDICE C – PROGRAMA PARA TREINAMENTO DE RNC

Abaixo seguem detalhes do código do programa de treinamento de uma amostra de curvas I-V. A Figura 77 mostra como o modelo de RNC é criado a partir da arquitetura escolhida. Na sequência, a Figura 78 mostra a carga de imagens estruturada, que já pré-classifica as imagens em função da pasta onde estão armazenadas (uma pasta para cada classe).

Figura 77 – Configuração dos parâmetros para geração de uma amostra.

```
def Executa_treinamento( ParametrosTreinamento, ParametrosAmostra ):
    ...

    Inicializa_ambiente( ParametrosTreinamento, ParametrosAmostra )

    MatrizTreinamento, MatrizValidacao, DiretorioImagens = Carrega_dados_treinamento( ParametrosTreinamento, ParametrosAmostra )

    Modelo = Constroi_modelo_Lenet5( ParametrosTreinamento, ParametrosAmostra )

    Modelo.summary()

    CurvaTreinamento, MelhorModelo, TempoTreinamento = Treina_modelo( Modelo, ParametrosTreinamento, ParametrosAmostra,
                                                                    MatrizTreinamento, MatrizValidacao, DiretorioImagens, Iteracao )
    ...
```

Fonte: Elaborado pelo autor.

Figura 78 – Carga de imagens a partir de um diretório.

```
def Carrega_dados_treinamento( ParametrosTreinamento, ParametrosAmostra ):

    if ParametrosAmostra[ 'FormatoImagem' ][2] == 1:
        TipoCor = 'grayscale'
    else:
        TipoCor = 'rgb'
    TamanhoImagem = (ParametrosAmostra[ 'FormatoImagem' ][0], ParametrosAmostra[ 'FormatoImagem' ][1])

    DiretorioImagens = os.getcwd() + ParametrosAmostra[ 'DiretorioImagens' ]
    MatrizTreinamento, MatrizValidacao = image_dataset_from_directory(
        directory = DiretorioImagens,
        validation_split = ParametrosTreinamento[ 'PercentualValidacao' ],
        batch_size = ParametrosTreinamento [ 'TamanhoLote' ],
        image_size = TamanhoImagem,
        color_mode = TipoCor,
        class_names = Classes,      # conforme definido pelo projeto de pesquisa
    ...
```

Fonte: Elaborado pelo autor.

A Figura 79 mostra a criação da respectiva camada convolucional conforme a arquitetura e das camadas conectadas de acordo com as configurações em cada experimento. A Figura 80 mostra a regularização do treinamento usando L1 e L2, além do *dropout*.

Figura 79 – Criação da camada convolucional.

```
def Constroi_modelo_Lenet5( ParametrosTreinamento, ParametrosAmostra ):

    Modelo = keras.Sequential()

    # Converte os valores dos pontos da imagem para entre 0 e 1
    Modelo.add( keras.layers.Rescaling(1./255, input_shape=ParametrosAmostra[ 'FormatoImagem' ]) )

    # Camadas de convolução, baseado em LENET-5, ajustado pelo projeto de pesquisa, conforme experimento
    Modelo.add( keras.layers.Conv2D( filters = 6, kernel_size=(5, 5), activation='relu' ) )
    Modelo.add( keras.layers.AveragePooling2D() )
    Modelo.add( keras.layers.Conv2D( filters = 16, kernel_size=(2, 2), activation='relu' ) )
    Modelo.add( keras.layers.AveragePooling2D() )
    Modelo.add( keras.layers.Flatten() )

    ...
```

Fonte: Elaborado pelo autor.

Figura 80 – Configuração da regularização durante treinamento.

```

Modelo.add( keras.layers.Dense(
    units = ParametrosTreinamento[ 'NumeroNeuronios' ],
    activation = 'relu',
    kernel_initializer = InicializadorPesos,
    kernel_regularizer = regularizers.L1L2( ParametrosTreinamento[ 'Regularizacao' ][0], ParametrosTreinamento[ 'Regularizacao' ][1] ),
    bias_regularizer = regularizers.L2( ParametrosTreinamento[ 'Regularizacao' ][2] ),
    activity_regularizer = regularizers.L2( ParametrosTreinamento[ 'Regularizacao' ][3] )
))
Modelo.add( keras.layers.Dropout( ParametrosTreinamento[ 'Regularizacao' ][4] ) )

```

Fonte: Elaborado pelo autor.

A Figura 81 mostra a compilação do modelo da RNC, incluindo o parâmetro de paciência para interromper o treinamento quando não houver mais redução da perda.

Figura 81 – Compilação do modelo RNC.

```

...
Modelo.compile(
    loss = keras.losses.sparse_categorical_crossentropy,
    optimizer = keras.optimizers.legacy.Adam(
        learning_rate = ParametrosTreinamento[ 'Otimizacao' ][0],
        decay = ParametrosTreinamento[ 'Otimizacao' ][1],
        epsilon = 1e-8 # Deeplearning.io
    ),
    metrics=[ 'sparse_categorical_accuracy', 'sparse_categorical_crossentropy' ],
)
...

def Treina_modelo( Modelo, ParametrosTreinamento, ParametrosAmostra, MatrizTreinamento, MatrizValidacao, DirectorioImagens, Iteracao ):
    ...
    ControleModelo = ModelCheckpoint(
        MelhorModelo,
        monitor='val_sparse_categorical_crossentropy',
        save_best_only = True,
        save_weights_only = True,
        verbose = MostrarDetalhesTreinamento
    )
    ...
    MonitorTreino = EarlyStopping(
        monitor='val_sparse_categorical_crossentropy',
        patience = ParametrosTreinamento[ 'Paciencia' ],
        restore_best_weights = True,
        verbose = MostrarDetalhesTreinamento
    )
    ...

    # Executa o treinamento, conforme definido no projeto de pesquisa
    CurvaTreinamento = Modelo.fit(
        MatrizTreinamento,
        None,
        batch_size = ParametrosTreinamento [ 'TamanhoLote' ],
        steps_per_epoch = int(len( MatrizTreinamento )),
        epochs = ParametrosTreinamento [ 'NumeroEpocas' ],
        shuffle = True,
        verbose = MostrarDetalhesTreinamento,
        validation_data = (MatrizValidacao, None),
        callbacks=[ControleModelo,MonitorTreino]
    )
    ...

```

Fonte: Elaborado pelo autor.

A Figura 82 mostra a chamada da rotina de predição, que carrega o melhor modelo (melhores pesos) e aplica sobre a base de validação cruzada)

Figura 82 – Chamada da rotina de predição.

```

# Avalia o modelo e salva o resultado num CSV
def Avalia_modelo( Modelo, MelhorModelo, TempoTreinamento, MatrizTreinamento, MatrizValidacao, Iteracao ):

    Modelo.load_weights( MelhorModelo )
    AvaliaTreinamento = Modelo.evaluate( MatrizTreinamento, verbose = MostrarDetalhesTreinamento )
    AvaliaValidacao = Modelo.evaluate( MatrizValidacao, verbose = MostrarDetalhesTreinamento )

    # Salva o modelo completo
    Modelo.save( MelhorModelo.replace( 'pesos_', 'modelo_' ) )

    Predicao = Modelo.predict( MatrizValidacao, verbose = MostrarDetalhesTreinamento )
    Predicao = Predicao.argmax(axis=-1)

```

Fonte: Elaborado pelo autor.

APÊNDICE D – PROGRAMA DE PREDIÇÃO COM MODELO DE RNC

Abaixo seguem detalhes do código do programa de predição de cada amostra de teste a partir do melhor modelo treinado em etapa anterior. A Figura 83 mostra a carga de imagens estruturada, que já pré-classifica as imagens em função da pasta onde estão armazenadas (uma pasta para cada classe).

Figura 83 – Carga de parâmetros e imagens para predição.

```
def Carrega_dados_analise( ParametrosAmostra ):

    if ParametrosAmostra['FormatoImagem'][2] == 1:
        TipoCor = 'grayscale'
    else:
        TipoCor = 'rgb'
    TamanhoImagem = (ParametrosAmostra['FormatoImagem'][0], ParametrosAmostra['FormatoImagem'][1])

    DiretorioImagens = os.getcwd() + ParametrosAmostra['DiretorioImagens']
    MatrizAnalise = image_dataset_from_directory(
        directory = DiretorioImagens,
        image_size = TamanhoImagem,
        color_mode = TipoCor,
        crop_to_aspect_ratio = True,
        interpolation='bicubic',
        ...
    )
```

Fonte: Elaborado pelo autor.

A Figura 84 mostra a carga do melhor modelo (arquitetura e pesos) e execução da predição. Por fim, a Figura 85 mostra os resultados das métricas sendo salvos em um arquivo CSV.

Figura 84 – Carga do melhor modelo para predição.

```
def Analisa_modelo( ParametrosAmostra, MatrizAnalise ):

    MelhorModelo = ParametrosAmostra['MelhorModelo']

    Modelo = load_model( MelhorModelo )

    AvaliaTreinamento = Modelo.evaluate( MatrizAnalise, verbose = MostrarDetalhesTreinamento )

    Predicao = Modelo.predict( MatrizAnalise, verbose = MostrarDetalhesTreinamento )
    Predicao = Predicao.argmax(axis=-1)
```

Fonte: Elaborado pelo autor.

Figura 85 – Gravação de arquivo CSV com indicadores.

```
def Salva_resultado_analise( ParametrosAmostra, ResultadoAnalise ):

    dd = pd.DataFrame( {
        'Fase' : ParametrosAmostra['Fase'],
        'Etapa' : ParametrosAmostra['Etapa'],
        'Experimento' : ParametrosAmostra['Experimento'],
        'Amostra' : ParametrosAmostra['Amostra'],
        'Iteracao' : ParametrosAmostra['Iteracao'],
        'TipoCurva' : ParametrosAmostra['TipoCurva'],
        'NumeroClasses' : ParametrosAmostra['NumeroClasses'],
        'PontosCurva' : ParametrosAmostra['PontosCurva'],
        'FormatoImagem' : str(ParametrosAmostra['FormatoImagem']),
        'Acuraria' : '{:,.03f}'.format(100*ResultadoAnalise['Acuraria']).replace(".", "%").replace(",", ".").replace("%", ","),
        'Perda' : '{:,.03f}'.format(ResultadoAnalise['Perda']).replace(".", "%").replace(",", ".").replace("%", ","),
        'Precisao' : '{:,.03f}'.format(100*ResultadoAnalise['Precisao']).replace(".", "%").replace(",", ".").replace("%", ","),
        'Sensibilidade' : '{:,.03f}'.format(100*ResultadoAnalise['Sensibilidade']).replace(".", "%").replace(",", ".").replace("%", ","),
        'F1Score' : '{:,.03f}'.format(100*ResultadoAnalise['F1Score']).replace(".", "%").replace(",", ".").replace("%", ",")
    } )
```

Fonte: Elaborado pelo autor.