



UNIVERSIDADE FEDERAL DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

ALAN MARQUES DA ROCHA

REDE NEURAL CONVOLUCIONAL HÍBRIDA OTIMIZADA POR ALGORITMOS
GENÉTICOS PARA CLASSIFICAÇÃO EM IMAGENS ELETROLUMINESCENTES
DE CÉLULAS FOTOVOLTAICAS

SOBRAL

2024

ALAN MARQUES DA ROCHA

REDE NEURAL CONVOLUCIONAL HÍBRIDA OTIMIZADA POR ALGORITMOS
GENÉTICOS PARA CLASSIFICAÇÃO EM IMAGENS ELETROLUMINESCENTES DE
CÉLULAS FOTOVOLTAICAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Algoritmos e Computação Distribuída.

Orientador: Prof. Dr. Carlos Alexandre Rolim Fernandes.

Coorientador: Prof. Dr. Marcelo Marques Simões de Souza.

SOBRAL

2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

R571r Rocha, Alan Marques da.

Rede Neural Convolutiva Híbrida Otimizada por Algoritmos Genéticos para Classificação em Imagens Eletroluminescentes de Células Fotovoltaicas / Alan Marques da Rocha. – 2024.
83 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2024.

Orientação: Prof. Dr. Carlos Alexandre Rolim Fernandes.

Coorientação: Prof. Dr. Marcelo Marques Simões de Souza.

1. Detecção automática de defeitos. 2. Rede neural convolutiva híbrida. 3. Célula fotovoltaica. 4. Ajuste fino de hiperparâmetros. 5. Algoritmos genéticos evolutivos. I. Título.

CDD 621.3

ALAN MARQUES DA ROCHA

REDE NEURAL CONVOLUCIONAL HÍBRIDA OTIMIZADA POR ALGORITMOS
GENÉTICOS PARA CLASSIFICAÇÃO EM IMAGENS ELETROLUMINESCENTES DE
CÉLULAS FOTOVOLTAICAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e de Computação. Área de Concentração: Algoritmos e Computação Distribuída.

Aprovada em: 26 de setembro de 2024

BANCA EXAMINADORA

Prof. Dr. Carlos Alexandre Rolim
Fernandes. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Marcelo Marques Simões de
Souza. (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Iális Cavalcante de Paula Júnior
Universidade Federal do Ceará (UFC)

Prof. Dr. Rodrigo de Melo Souza Veras
Universidade Federal do Piauí (UFPI)

Dedico este trabalho a minha adorável Mãe Maria Iracema Marques da Rocha (*In Memoriam*).

AGRADECIMENTOS

À minha saudosa e amada mãe Maria Iracema Marques da Rocha (*in memoriam*), por ter sido meu porto seguro e por todo o seu amor incondicional dedicado à mim durante sua trajetória de vida.

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos durante o meu período no curso de mestrado.

Ao meu orientador Prof. Dr. Carlos Alexandre Rolim Fernandes e ao meu coorientador Prof. Dr. Marcelo Marques Simões de Souza, pela paciência, orientação e conhecimentos compartilhados. Meus sinceros agradecimentos.

“Aqueles que passam por nós, não vão sós, não nos deixam sós. Deixam um pouco de si, levam um pouco de nós.”

(Antoine de Saint-Exupéry)

RESUMO

A demanda global por energia elétrica vem aumentando exponencialmente nos últimos anos. Diante disso, investimentos em fontes de energia renovável têm se tornado cada vez mais necessários, destacando-se a energia solar fotovoltaica (FV) como uma fonte de fácil instalação e baixo custo. O crescimento da capacidade instalada de fontes de geração FV traz demandas por métodos sofisticados e precisos para a detecção de defeitos nas células que compõem tal sistema. O presente trabalho propõe um método para classificação de células FVs de silício monocristalino (Si-m) e policristalino (Si-p) em funcionais e não-funcionais, utilizando uma *Hybrid Convolutional Neural Network* (HCNN) com as arquiteturas ResNet50 e VGG16 pré-treinadas com a base de dados ImageNet para a extração de características das imagens, onde os melhores hiperparâmetros de cada rede foram obtidos por meio de Algoritmos Genéticos Evolutivos (AGE). O processo de classificação da HCNN foi feito por meio de uma *Support Vector Machine* (SVM). Quatro experimentos de classificação foram realizados. Inicialmente, foram testados algoritmos elementares como SVM, *Naïve Bayes* (NB), *k-Nearest Neighbors* (k-NN) e *Random Forest* (RF). Subsequentemente, foram realizados experimentos com as arquiteturas ResNet50, VGG16 e *InceptionV3*. Os modelos de HCNN ResNet50+SVM e VGG16+SVM foram testadas com a base de dados original contendo 2.624 amostras e com a base de dados aumentada, contendo 13.120 imagens. O ajuste fino utilizando AGE sem aumento de dados, resultou na topologia VGG16+SVM alcançando uma acurácia de 95,21% e um índice *Kappa* de 78,23%. Por fim, como resultado principal deste trabalho, a mesma topologia de HCNN superou seu desempenho anterior, alcançando uma acurácia de 99,67% e um índice *Kappa* de 80,17% com aumento de dados. O modelo ResNet50+SVM também mostrou resultados robustos com aumento de dados, atingindo uma acurácia de 98,17% e um índice *Kappa* de 85,26%. Esses resultados evidenciam a eficácia das técnicas propostas, posicionando a HCNN otimizada por AGE e aumento de dados como uma solução promissora para a detecção automática de defeitos em células FVs de Si-m e Si-p.

Palavras-chave: Detecção automática de defeitos; Rede neural convolucional híbrida; Célula fotovoltaica; Ajuste fino de hiperparâmetros; Algoritmos genéticos evolutivos.

ABSTRACT

The global demand for electricity has been increasing exponentially in recent years. In light of this, investments in renewable energy sources have become increasingly necessary, with photovoltaic (PV) solar energy standing out as a source that is easy to install and cost-effective. The growth of the installed capacity of PV generation sources brings a demand for sophisticated and precise methods to detect defects in the cells that make up such systems. This work proposes a method for classifying monocrystalline silicon (Si-m) and polycrystalline silicon (Si-p) PV cells into functional and non-functional categories, using a Hybrid Convolutional Neural Network (HCNN) based on ResNet50 and VGG16 architectures, pre-trained with the ImageNet database to extract image features, where the best hyperparameters for each network were obtained through Evolutionary Genetic Algorithms (EGA). The classification process of the HCNN was conducted using a Support Vector Machine (SVM). Four classification experiments were performed. Initially, elementary algorithms such as SVM, Naïve Bayes (NB), k-Nearest Neighbors (k-NN), and Random Forest (RF) were tested. Subsequently, experiments were conducted with the ResNet50, VGG16, and InceptionV3 architectures. The HCNN models ResNet50+SVM and VGG16+SVM were tested with the original dataset containing 2.624 samples and an augmented dataset containing 13.120 images. The fine-tuning using EGA without data augmentation resulted in the VGG16+SVM topology achieving an accuracy of 95.21% and a Kappa index of 78.23%. Finally, as the main result of this work, the same HCNN topology surpassed its previous performance, achieving an accuracy of 99.67% and a Kappa index of 80.17% with data augmentation. The ResNet50+SVM model also showed robust results with data augmentation, achieving an accuracy of 98.17% and a Kappa index of 85.26%. These results highlight the effectiveness of the proposed techniques, positioning the HCNN optimized by EGA and data augmentation as a promising solution for the automatic detection of defects in Si-m and Si-p PV cells.

Keywords: Automatic defect detection; Hybrid convolutional neural network; Photovoltaic cell; Fine-tuning of hyperparameters; Evolutionary genetic algorithms.

LISTA DE FIGURAS

| | | |
|-----------|---|----|
| Figura 1 | – Fluxograma das gerações de células fotovoltaicas e seus respectivos materiais. | 28 |
| Figura 2 | – Imagens em eletroluminescência de células fotovoltaicas de silício: (a) monocristalino funcional. (b) monocristalino com defeito de ponto quente, trinca e microtrinca. (c) policristalino funcional. (d) policristalino com defeito de ponto quente e microtrinca. | 30 |
| Figura 3 | – Representação da aplicação da técnica <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE) em uma imagem de célula FV de Si-m. | 33 |
| Figura 4 | – Etapas da convolução em uma imagem I de (5×5) pixels com um filtro de tamanho (3×3) e <i>stride</i> igual a 1. | 37 |
| Figura 5 | – Aguçamento, detecção de borda horizontal e vertical em uma célula fotovoltaica de silício monocristalino com defeitos de trincas. | 38 |
| Figura 6 | – Representação da operação de <i>pooling</i> com valores máximo, médio e mínimo com uma janela de tamanho (2×2) e <i>stride</i> igual a 2. | 39 |
| Figura 7 | – Fluxograma exemplificando a transferência de aprendizagem e ajuste fino em um modelo de Rede Neural Convolutacional. | 43 |
| Figura 8 | – Imagens em eletroluminescência de células fotovoltaicas de silício: (a) monocristalino funcional. (b) monocristalino com defeitos de trincas e microtrincas. (c) policristalino funcional. (d) policristalino com defeito de rachadura, trincas e delaminação. | 51 |
| Figura 9 | – Resultado das técnicas de aumento de dados empregadas na base de imagens. (a) Original. (b) Rotação em 90° no sentido horário. (c) Rotação em 90° no sentido anti-horário. (d) Espelhamento (<i>flipping</i>). (e) Borramento e (f) Aumento do brilho em 20%. | 52 |
| Figura 10 | – (a) Imagem original da célula fotovoltaica de silício policristalino. (b) Imagem resultante da aplicação da técnica CLAHE. (c) Histograma da intensidade dos pixels da imagem original. (d) Histograma da intensidade dos pixels após a aplicação da técnica CLAHE. | 54 |
| Figura 11 | – Modelo de Rede Neural Convolutacional Híbrida para Classificação de Defeitos de Células Fotovoltaicas em Funcionais e Não-funcionais. | 58 |
| Figura 12 | – (a) Matriz de confusão do melhor resultado obtido pela HCNN VGG16+SVM. (b) Matriz de confusão do melhor resultado obtido pela HCNN ResNet50+SVM. | 70 |

Figura 13 – Exemplos de classificações realizadas pelo modelo VGG16+SVM com aumento de dados, onde a classe 0.0 representa as imagens de células FVs funcionais e a classe 1.0 representa as imagens de células FVs não-funcionais. 74

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 – Características dos trabalhos levantados no estado da arte | 25 |
| Tabela 2 – Rendimento médio de células FVs de acordo com a tecnologia empregada. . | 29 |
| Tabela 3 – Concordância do índice <i>Kappa</i> | 48 |
| Tabela 4 – Espaço de pesquisa de hiperparâmetros: Tipos de hiperparâmetros, suas possibilidades e quantidades. | 57 |
| Tabela 5 – Resultado da acurácia dos classificadores elementares em cada <i>fold</i> | 62 |
| Tabela 6 – Resultado da sensibilidade dos classificadores elementares em cada <i>fold</i> . . . | 62 |
| Tabela 7 – Resultado da precisão dos classificadores elementares em cada <i>fold</i> | 63 |
| Tabela 8 – Resultado dos classificadores elementares por meio da métrica <i>F-score</i> | 63 |
| Tabela 9 – Hiperparâmetros das Redes ResNet50, VGG16 e <i>InceptionV3</i> | 64 |
| Tabela 10 – Resultado da acurácia dos modelos de aprendizado profundo ResNet50, VGG16 e <i>InceptionV3</i> em cada <i>fold</i> utilizando a base de dados aumentada e com as imagens pré-processadas com a técnica CLAHE. | 65 |
| Tabela 11 – Resultado da sensibilidade dos modelos de aprendizado profundo ResNet50, VGG16 e <i>InceptionV3</i> em cada <i>fold</i> | 65 |
| Tabela 12 – Resultado da precisão dos modelos de aprendizado profundo ResNet50, VGG16 e <i>InceptionV3</i> em cada <i>fold</i> | 66 |
| Tabela 13 – Resultado do <i>F-score</i> dos modelos de aprendizado profundo ResNet50, VGG16 e <i>InceptionV3</i> em cada <i>fold</i> | 66 |
| Tabela 14 – Resultados do ajuste fino genético para os dez melhores indivíduos das topologias ResNet50+SVM e VGG16+SVM, suas características e métricas obtidas utilizando a base de dados contendo 2.624 amostras. | 68 |
| Tabela 15 – Resultados do ajuste fino genético para os dez melhores indivíduos das topologias ResNet50+SVM e VGG16+SVM, suas características e métricas obtidas utilizando a base de dados aumentada contendo 13.120 amostras. . . | 69 |
| Tabela 16 – Melhores resultados de acurácia por experimento e aumento percentual em relação ao experimento anterior. | 71 |
| Tabela 17 – Resultados do estado da arte para detecção de defeitos em células de módulos fotovoltaicos em comparação com os melhores resultados do trabalho proposto. . | 73 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|---|
| A_{cc} | Acurácia |
| S_s | Sensibilidade |
| AFG | Ajuste Fino Genético |
| CLAHE | <i>Contrast Limited Adaptive Histogram Equalization</i> |
| CNN | <i>Convolutional Neural Network</i> |
| DT | <i>Decision Tree</i> |
| E | Especificidade |
| EL | Eletroluminescência |
| ELPV | <i>Electroluminescence Photovoltaic Dataset</i> |
| FN | Falso Negativo |
| FP | Falso Positivo |
| FV | Fotovoltaica |
| HCNN | <i>Hybrid Convolutional Neural Network</i> |
| k-NN | <i>k-Nearest Neighborhood</i> |
| ML | <i>Machine Learning</i> |
| NB | <i>Naïve Bayes</i> |
| P | Precisão |
| RF | <i>Random Forest</i> |
| Si-m | Silício monocristalino |
| Si-p | Silício policristalino |
| SVM | <i>Support Vector Machine</i> |
| VN | Verdadeiro Negativo |
| VP | Verdadeiro Positivo |

LISTA DE SÍMBOLOS

| | |
|----------|------------------------------|
| C | Coeficiente de Regularização |
| MW | Megawatt |
| Si | Silício |
| TWh | Terawatt-hora |
| W | Watt |
| κ | Índice <i>Kappa</i> |
| I | Imagem |

SUMÁRIO

| | | |
|--------------|---|-----------|
| 1 | INTRODUÇÃO | 16 |
| 1.1 | Objetivo Geral | 18 |
| 1.2 | Objetivos Específicos | 19 |
| 1.3 | Contribuições do Trabalho | 19 |
| 1.4 | Produção Científica | 19 |
| 1.5 | Organização do Trabalho | 20 |
| 2 | TRABALHOS RELACIONADOS | 22 |
| 3 | CÉLULAS FOTOVOLTAICAS E ELETROLUMINESCÊNCIA | 27 |
| 3.1 | Células Fotovoltaicas | 27 |
| 3.2 | Eletroluminescência em Células Fotovoltaicas | 28 |
| 4 | PRÉ-PROCESSAMENTO | 31 |
| 4.1 | Contrast Limited Adaptive Histogram Equalization (CLAHE) | 31 |
| 4.2 | Aumento de Dados | 32 |
| 5 | APRENDIZADO PROFUNDO | 35 |
| 5.1 | Redes Neurais Convolucionais (CNNs) | 35 |
| 5.1.1 | <i>Camada de Convolução</i> | 36 |
| 5.1.2 | <i>Camada de Pooling</i> | 38 |
| 5.2 | Hiperparâmetros | 39 |
| 5.3 | Transferência de Aprendizado e Ajuste Fino | 40 |
| 5.4 | Sistemas Genéticos Evolutivos | 42 |
| 5.5 | SVM | 44 |
| 5.5.1 | <i>Forma linear</i> | 45 |
| 5.5.2 | <i>Forma não-linear</i> | 45 |
| 5.6 | Validação do Modelo | 46 |
| 6 | METODOLOGIA | 50 |
| 6.1 | Base de Imagens | 50 |
| 6.2 | Aumento de Dados | 50 |
| 6.3 | Pré-processamento com <i>CLAHE</i> | 52 |
| 6.4 | Ajuste Fino Genético | 55 |
| 6.5 | Espaço de Busca dos Hiperparâmetros | 57 |

| | | |
|-------|--|----|
| 6.6 | HCNN | 58 |
| 6.6.1 | <i>Extração de Características</i> | 58 |
| 6.6.2 | <i>Configuração da SVM</i> | 59 |
| 7 | RESULTADOS E DISCUSSÕES | 61 |
| 7.1 | Experimentos de Classificação com Algoritmos Elementares | 61 |
| 7.2 | Experimentos de Classificação com os Modelos ResNet50, VGG16 e <i>InceptionV3</i> | 63 |
| 7.3 | Ajuste Fino Genético sem Aumento de Dados | 67 |
| 7.4 | Ajuste Fino Genético com Aumento de Dados | 69 |
| 7.5 | Comparação com o Estado da Arte | 72 |
| 7.6 | Resultados Visuais das Classificações | 72 |
| 7.7 | Desafios e Limitações | 74 |
| 8 | CONCLUSÕES E TRABALHOS FUTUROS | 76 |
| | REFERÊNCIAS | 77 |

1 INTRODUÇÃO

O crescente aumento da demanda e consumo de energia elétrica em escala global, impulsionado pelo desenvolvimento econômico, tecnológico e social, tem colocado em evidência a necessidade de explorar o uso de fontes de energia renováveis e sustentáveis para suprir o consumo. Neste cenário, a questão energética desponta como um dos principais desafios contemporâneos, com implicações ambientais locais e globais do planeta. Nesse contexto, é fundamental compreender a dinâmica do consumo de energia elétrica, as tendências no uso de geração de energias renováveis e as complexidades inerentes à busca por fontes mais sustentáveis de suprimento energético.

Segundo o anuário estatístico de energia elétrica (EPE, 2023), o consumo de energia elétrica mundial teve mudanças expressivas entre 2020 e 2021. A China teve um aumento de 9,7%, passando de 4.440 TWh para 4.846 TWh, enquanto os EUA mantiveram um crescimento de 2,1%, indo de 3.839 TWh para 3.979 TWh. A Índia teve um aumento considerável de 8,6%, de 892 TWh para 1.443 TWh, e a Rússia registrou um crescimento de 6,0%, de 891 TWh para 996 TWh. O Japão teve uma ligeira redução de 0,2%, caindo de 1.000 TWh para 913 TWh, enquanto o Brasil viu um aumento de 4,2%, de 498 TWh para 571 TWh.

Neste contexto, a geração de energia renovável tem conquistado um espaço considerável, tanto em escala global quanto nacional (EPE, 2023). A capacidade instalada de energia Fotovoltaica (FV) cresceu significativamente de 2020 para 2021, com um aumento médio de 18%, destacando-se a China, EUA e Índia, registrando aumentos de 20,9%, 24,3% e 26,1%, respectivamente (EPE, 2023). Em 2022, o Brasil apresentou um aumento significativo em sua capacidade instalada de fontes renováveis, com destaque para a energia solar, apresentando um aumento de 59,5% comparado a 2021, chegando a 7.387 MW (EPE, 2023). Esse salto é notável e reflete o crescente interesse por sistemas FVs no país, impulsionados por incentivos governamentais, redução de custos e consciência ambiental.

Apesar de suas vantagens, a geração de energia FV não está isenta de desafios. A falta de manutenção adequada pode resultar em defeitos que comprometem a eficiência e a vida útil desses sistemas. Esses defeitos, se não identificados e tratados a tempo, podem acarretar prejuízos econômicos e ambientais significativos (CHAUDHARY; CHATURVEDI, 2018). Ademais, os defeitos nesses sistemas podem ocorrer em várias etapas, incluindo a etapa de produção ou mesmo durante o transporte ou operação, como fatores elétricos, circuito aberto, curto-circuito, desconexão, dentre outros (CHAIBI *et al.*, 2019). Alguns outros defeitos, como

rachaduras ou trincas, podem ocorrer devido a fatores ambientais, como tempestades ou granizo (JAHN *et al.*, 2018). Entre todos os problemas, o superaquecimento tem sido apontado como uma grande falha nos sistemas FVs, ocasionando uma redução considerável na potência. Todos esses defeitos são importantes de se abordar, pois podem levar à perda de energia e falhas na potência de saída nos sistemas FVs (MADETI; SINGH, 2017a). Mais especificamente, esses defeitos podem levar a uma perda na potência de saída superior a 50% (TSANAKAS *et al.*, 2016). Ademais, esse problema técnico pode desencadear incêndios perigosos para a natureza e os seres humanos. Isso reforça a necessidade de detecção e diagnóstico eficazes para prolongar o ciclo de vida, juntamente com a manutenção adequada do sistema FV, evitando incidentes.

A literatura tem apresentado diferentes métodos para a análise de defeitos nos módulos FVs. Trabalhos como Yi e Etemadi (2017) visam detectar falhas ocasionadas por problemas na interconexão elétrica entre as células em arranjos FVs em uma ampla gama de situações, incluindo falhas ocorridas em condições de baixa irradiância e alta impedância.

Para detectar falhas nos sistemas FVs, algoritmos de Aprendizado de Máquina, do inglês, *Machine Learning* (ML) têm recebido considerável atenção na literatura. Usando algoritmos de ML, várias técnicas foram empregadas, como processamento baseado em tensão e corrente (MADETI; SINGH, 2017b) e técnicas de processamento baseadas em imagem (AKRAM *et al.*, 2020). A utilização de técnicas baseadas em imagem tem sido bastante útil na melhoria do processo de detecção de falhas em sistemas FVs (TSANAKAS *et al.*, 2016). Em todos os métodos baseados em processamento de imagem, o ML foi extensivamente adotado para distinguir entre os sistemas FVs funcionais e não-funcionais.

A aplicação da termografia infravermelha na manutenção preventiva e na avaliação da integridade desses dispositivos é objeto de extensa investigação, dada a sua operacionalidade amigável e a precisão diagnóstica inerente à técnica, uma vez que a temperatura ótima de operação dos módulos é considerada um parâmetro de referência essencial na identificação precisa da localização de pontos de alta temperatura (BALASUBRAMANI *et al.*, 2020). Nesse sentido, o uso de algoritmos de ML, como regras difusas (JAFFERY *et al.*, 2017), método *Naïve Bayes* (NIAZI *et al.*, 2019), algoritmo *k-means* (NIAZI *et al.*, 2019), tem sido amplamente adotado para detectar e classificar pontos quentes ou posições de falha usando imagens térmicas. A termografia é principalmente usada para detectar falhas onde a temperatura é alta, devido a curtos-circuitos e ameaças de incêndio (MÁRQUEZ; RAMÍREZ, 2019). Além disso, a imagem de Eletroluminescência (EL) é considerada uma abordagem confiável para identificar as falhas

em células FVs que podem levar à degradação do módulo FV (ISLAM *et al.*, 2018; MENG *et al.*, 2022).

Redes neurais, incluindo as convolucionais do inglês, *Convolutional Neural Network* (CNN), artificiais e profundas, são empregadas para criar uma metodologia baseada em imagem para identificar e classificar falhas no sistema FV (HERRAIZ *et al.*, 2020). Em trabalhos relacionados anteriores, foi comprovado que os algoritmos de ML permitem detectar falhas em painéis FVs com base em parâmetros de corrente, tensão, imagens térmicas, imagens em EL, etc. Apesar disso, ainda existem muitas limitações nos métodos anteriores, como a quantidade e o tipo de dados utilizados e a precisão do desempenho, que requerem mais investigação.

Diante disso, este trabalho apresenta uma metodologia completa para a detecção automática de defeitos em imagens EL de células de Silício monocristalino (Si-m) e Silício policristalino (Si-p), através de uma Rede Neural Convolucional Híbrida, do inglês, *Hybrid Convolutional Neural Network* (HCNN), onde adotou-se uma CNN para extração de características das imagens em combinação com a *Support Vector Machine* (SVM) (CORTES; VAPNIK, 1995) utilizado como classificador das imagens de células FVs em funcionais e não-funcionais, fornecendo um modelo robusto, de baixo custo computacional e que pode ser aplicado para a criação de um sistema de diagnóstico assistido por computador em um ambiente real como uma ferramenta de suporte ao especialista. A rede proposta foi treinada e validada em uma base de imagens amplamente utilizada na literatura, com 2.074 imagens de células FVs em EL de 300×300 pixels obtidas de 44 módulos FVs. Técnicas de aumento de dados foram implementadas para aumentar o número de amostras utilizadas no treinamento do modelo proposto. Ademais, adotou-se uma metodologia de pré-processamento das imagens e o ajuste fino dos hiperparâmetros da rede através de algoritmo genético.

1.1 Objetivo Geral

O objetivo geral deste trabalho é propor um modelo computacional de aprendizado profundo que discrimina células fotovoltaicas de silício monocristalino e policristalino em funcionais ou não-funcionais a partir de imagens em eletroluminescência, através de uma topologia de HCNN.

1.2 Objetivos Específicos

Destacam-se como objetivos específicos:

- Realizar um levantamento do estado da arte sobre o emprego do aprendizado profundo na classificação de defeitos em células FVs utilizando imagens em EL;
- Empregar técnicas de aumento de dados para melhorar o desempenho do modelo;
- Realizar o ajuste fino de hiperparâmetros da rede através de algoritmos genéticos para que o modelo proposto possa adquirir um nível ótimo de generalização e redução do seu custo computacional;
- Comparar o modelo proposto com os algoritmos de ML amplamente utilizados na literatura.

1.3 Contribuições do Trabalho

Este trabalho trás ao meio científico as seguintes contribuições:

- Uma estratégia para a escolha de hiperparâmetros para a HCNN de rápida convergência, controle de *overfitting* e boa capacidade de generalização;
- Uma arquitetura de rede que é mais competitiva em desempenho e complexidade do que as topologias de CNNs comumente utilizadas na literatura para análise de defeitos de células FVs;
- Uma topologia de HCNN otimizada com um método para o ajuste fino de hiperparâmetros da CNN e configurações da SVM, produzindo um modelo eficaz e customizável para a detecção de células funcionais e não-funcionais em imagens de células FVs de Si-m e Si-p.

1.4 Produção Científica

Durante a elaboração dessa dissertação e por meio dos resultados obtidos os seguintes artigos científicos foram submetidos e aceitos para publicação:

A. M. da Rocha, M. M. S. de Souza, F. L. Serafim, C. A. R. Fernandes, Í. B. Viana, "*Modelo Computacional para Discriminação de Células Fotovoltaicas Defeituosas em Imagens Eletroluminescentes*", **XVI Simpósio Brasileiro de Automação Inteligente (SBAI)**, Manaus - AM, 15 a 18 de outubro, 2023.

A. M. da Rocha, M. M. S. de Souza, F. L. Serafim, C. A. R. Fernandes, "*Análise de Defeitos em Células Fotovoltaicas Através da Matriz de Coocorrência de Níveis de Cinza*", **XVI**

Simpósio Brasileiro de Automação Inteligente (SBAI), Manaus - AM, 15 a 18 de outubro, 2023.

A. M. da Rocha, M. M. S. de Souza, C. A. R. Fernandes, "*Método computacional para automação na detecção de defeitos em células fotovoltaicas utilizando imagens em eletroluminescência*", **XXV Congresso Brasileiro de Automática (CBA)**, Rio de Janeiro - RJ, 15 a 18 de outubro, 2024.

1.5 Organização do Trabalho

Essa dissertação está organizada em oito capítulos, conforme a seguinte estrutura:

Capítulo 2: Discorre sobre o estado da arte e aborda as principais pesquisas que serviram como fundamentação teórica para este trabalho.

Capítulo 3: Apresenta as principais características das células FVs de Si-m e Si-p e discorre sobre a técnica de EL e como a mesma é utilizada na inspeção de defeitos em células FVs.

Capítulo 4: Discorre sobre o pré-processamento das imagens, além da utilização do método da Equalização Adaptativa de Histograma com Limite de Contraste, do inglês, *Contrast Limited Adaptive Histogram Equalization (CLAHE)* como método de pré-processamento, além de abordar as técnicas de aumento de dados utilizadas para a aquisição de novas imagens.

Capítulo 5: Neste capítulo os conceitos teóricos de aprendizado profundo serão apresentados. As técnicas de ajuste fino, transferência de aprendizado e algoritmos genéticos são discutidas fornecendo uma fundamentação teórica para a obtenção dos hiperparâmetros da HCNN. Por fim, o capítulo encerra apresentando o classificador SVM e as técnicas de validação utilizadas neste trabalho.

Capítulo 6: Apresenta a base de dados e os detalhes da metodologia proposta para a classificação de células FVs em funcionais e não-funcionais.

Capítulo 7: Fornece e discute os resultados obtidos em quatro experimentos de classificação, a saber: (i) Análise dos resultados por meio dos classificadores elementares *Random Forest (RF)*, *SVM*, *Naïve Bayes (NB)* e *Decision Tree (DT)*, com o intuito de realizar comparações com os resultados obtidos pelo modelo HCNN. (ii): Classificação por meio das topologias *Resnet50*, *VGG16* e *InceptionV3* pré-treinadas com ImageNet (DENG *et al.*, 2009) com e sem aumento de dados, (iii) Implementação da HCNN na classificação sem aumento de dados e (iv) implementação da HCNN em conjunto com a base de dados aumentada.

Capítulo 8: São fornecidas as conclusões obtidas no decorrer deste estudo, destacando os principais resultados, assim como perspectivas para trabalhos futuros.

2 TRABALHOS RELACIONADOS

A grande demanda de geração e consumo de energia elétrica fez com que os sistemas FVs fossem amplamente utilizados para suprir as necessidades de consumo. Neste contexto, diversas técnicas de análise de defeitos a nível de célula estão sendo desenvolvidas na literatura, destacando-se os métodos implementados através de algoritmos de aprendizado profundo. Nesta seção, são relatados os trabalhos levantados na pesquisa do estado da arte.

Et-taleby *et al.* (2022) propõe um modelo combinado de CNN e SVM para a classificação de defeitos em células FVs de Si-m e Si-p. No referido trabalho dois conjuntos de dados, D1 e D2, são utilizados contendo imagens em EL de células FVs. O conjunto D1 contém 2.624 imagens de células Si-m e Si-p, rotuladas como funcionais ou defeituosas. O conjunto D2 contém 1.028 imagens, classificadas em três categorias: funcionais, corroídas e trincadas. A extração de atributos das imagens foi realizada utilizando a arquitetura VGG16, apresentando mais de 138 milhões de parâmetros. Em seguida, os atributos extraídos foram utilizados em conjunto com uma SVM para a classificação das imagens em suas respectivas categorias de defeitos, através de experimentos de validação cruzada (*k-fold*) com $k = 5$. O modelo proposto pelos autores alcançou uma acurácia média de 99,49% e 99,46% para os conjuntos de dados D1 e D2, respectivamente. Embora os resultados tenham sido promissores, nenhuma técnica de pré-processamento e ajuste fino foi utilizada para a redução dos parâmetros da rede profunda.

Fan *et al.* (2022) apresentaram um modelo para a detecção de microtrincas em células Si-p em imagens EL, utilizando a arquitetura ResNet. Para melhorar a precisão da detecção, os autores empregaram um módulo de fusão de recursos, no qual combina informações de baixo e alto nível para a classificação. Ademais, os autores propuseram um método de aprendizado de transferência para aprimorar a detecção de defeitos das células. As técnicas de pré-processamento utilizadas incluem o aumento de dados, através do método de *flip*, para tratar o desbalanceamento dos dados e a filtragem de Fourier, que remove interferências de ruído causadas por barramentos nas células solares. Além disso, foi utilizado o Padrão Binário Local, do inglês, *Local Binary Pattern* (LBP) para extrair características de textura local das imagens, destacando possíveis microtrincas semelhantes a linhas, fundamentais para a detecção de defeitos em células Si-p. Como resultado, o método proposto alcançou uma acurácia de 99,11%.

Tang *et al.* (2022) propõem um algoritmo para a detecção de defeitos lineares em imagens EL de células FVs de Si-p através da implementação de uma CNN resultando em 5 milhões de parâmetros. Os autores focaram em imagens de Si-p, devido a dificuldade de extrair

os atributos das imagens do fundo da célula. O algoritmo baseia-se em três etapas, a saber: extração de atributos, pós-processamento dos resultados extraídos na primeira etapa e por fim, a implementação de uma CNN para realizar a classificação dos defeitos lineares das imagens. Nas etapas 1 e 2, a extração de atributos foi realizada por meio da matriz Hessiana e o aprimoramento dos atributos resultantes foram melhorados através de um detector de linha multiescala. A topologia da CNN proposta foi comparada com os modelos ResNet50, *InceptionV3*, VGG16, NASNet-A, PNASNet, chegando a uma acurácia de 93%. Nenhuma técnica de aumento de dados ou ajuste fino foi utilizada.

Em outro estudo, Demirci *et al.* (2021) propõem uma nova estrutura automática de detecção e classificação de defeitos multiclasse em células FVs de Si-m e Si-p em imagens EL, utilizando o método *Deep Feature-Based* (DFB). Neste método, os atributos das imagens são extraídas por meio de uma *Deep Neural Network* (DNN) e classificadas através dos algoritmos SVM, *k-Nearest Neighborhood* (k-NN), DT, RF e NB. Para aumentar o conjunto de dados os autores realizaram um aumento de dados *offline*, rotacionando as imagens em 90°, 180° e 270°, respectivamente. O algoritmo *minimum Redundancy Maximum Relevance* (mRMR) é empregado para selecionar os melhores atributos das diferentes camadas das DNNs, reduzindo as dimensões dos vetores de atributos e aumentando o desempenho da classificação. Ademais, os autores propõem uma arquitetura de CNN híbrida denominada de *Lightweight Convolutional Neural Network* (L-CNN) que foi treinada do zero. Os resultados mostraram que o método DFB com SVM obteve as acurácias mais altas, com 90,57% e 94,52% para o conjuntos de dados com 4 e 2 classes, respectivamente.

Acharya *et al.* (2021) realizam uma análise de células FVs de Si-m e Si-p em imagens EL e as classificaram em funcionais, microtrincas, trincas visíveis e corrosão, através da implementação de uma *Deep Siamese CNN* (DS-CNN) (KOCH *et al.*, 2015), usada principalmente para aprender uma métrica de similaridade entre pares de imagens (ACHARYA *et al.*, 2021). Um pré-processamento foi realizado na base de imagens através do método *Random Sample Consensus* (RANSAC) para a transformação geométrica apropriada das imagens antes do processo de aprendizado. Em termos de acurácia o algoritmo proposto obteve 86% para a categoria de células sem defeitos, 52% para microtrincas, 67% para trincas visíveis e 94% para células que apresentavam defeito de corrosão, obtendo uma acurácia média de 74,75%.

Em Tang *et al.* (2020) os autores investigaram a detecção de defeitos em células FVs de Si-m e Si-p em imagens EL. Para isso, propuseram uma abordagem para o aumento de

dados que combina técnicas de processamento de imagem tradicional, gerando novas imagens através do rotacionamento em 90°, 180° e 270° das imagens originais, bem como o espelhamento vertical e horizontal de maneira aleatória. Ademais, Redes Adversárias Generativas, do inglês, *Generative Adversarial Network* (GAN) foram utilizadas como metodologia adicional para aumentar o número de amostras de imagens EL. Uma topologia de CNN com aproximadamente 13 milhões de parâmetros foi proposta para a classificação automática dos defeitos nas imagens EL. A solução foi avaliada utilizando os modelos de aprendizado profundo VGG16, ResNet50, *InceptionV3* e MobileNet. O melhor resultado que os autores obtiveram em termos de acurácia foi de 83%. Nenhuma etapa de pré-processamento e ajuste fino de hiperparâmetros foi utilizada, dando margem à uma melhoria do método proposto pelos autores.

Mathias *et al.* (2020) realizaram um trabalho para detectar microtrincas presentes em módulos FVs de Si-p em imagens EL utilizando técnicas de extração de atributos em combinação com os algoritmos SVM e *Backpropagation Neural Network* (BPNN). Os autores dividiram seu conjunto de dados em 2.000 imagens para o treinamento e 300 imagens para teste. Para extrair as características das imagens, utilizaram a *Discrete Wavelet Transform* (DWT) e a *Stationary Wavelet Transform* (SWT). Usando esses atributos, classificaram as imagens em trincadas e não-trincadas. A acurácia obtida pelos modelos foi de 92,68% para a SVM e 93,68% para o *Backpropagation Neural Network* (BPNN). Nenhuma técnica de aumento de dados ou ajuste fino foi proposta visando obter um melhor resultado no processo de classificação.

Deitsch *et al.* (2019) investigaram a classificação de defeitos em células FVs de Si-m e Si-p em imagens EL através de uma SVM e uma CNN da topologia VGG19, originalmente pré-treinada no conjunto de dados ImageNet. O aumento de dados foi utilizado para gerar amostras de treinamento adicionais ligeiramente perturbadas, através de rotações das imagens originais nos eixos vertical e horizontal. Em termos de classificação a CNN foi mais precisa e atingiu uma acurácia média de 88,42%. Já a SVM obteve uma acurácia média ligeiramente inferior de 82,44%. Nenhuma técnica de pré-processamento e ajuste fino foi proposta.

Akram *et al.* (2019) propoaram uma topologia de CNN através da busca exaustiva de hiperparâmetros, realizando variações entre o número de camadas de convolução e *pooling*, utilizando as topologias VGG19, VGG16, VGG13 e VGG11 como referência. Ademais, técnicas comumente utilizadas em aumento de dados como rotação e espelhamento foram utilizadas para a obtenção de novas imagens baseadas nas originais. O modelo resultante consistiu em seis camadas (4 convolucionais e 2 totalmente conectadas). A acurácia média obtida pelo modelo

proposto foi de 93,02%. Através da busca pelos hiperparâmetros ótimos do modelo, foi possível reduzir consideravelmente o custo computacional. A rede foi implementada sem a necessidade da utilização de Unidade Gráfica de Processamento, do inglês, *Graphics Processing Unit* (GPU).

Karimi *et al.* (2018) realizaram um processamento automatizado de dados que caracterizam os atributos de degradação observadas em imagens EL de módulos FVs de Si-m e Si-p, obtidas através de testes controlados. Inicialmente, realiza-se um pré-processamento das imagens em EL para reduzir os ruídos das imagens aplicando-se um filtro de mediana. Na extração de atributos das imagens, utilizam-se as 14 medidas propostas por Haralick (Haralick *et al.*, 1973). O algoritmo SVM foi implementado e comparado com uma topologia de CNN proposta pelos autores, obtendo acurácias médias de 98,95% e 98,24%, respectivamente. No presente caso a SVM superou os resultados obtidos pela CNN. Nenhuma técnica de aumento de dados ou ajuste fino foi utilizada, implicando em uma menor capacidade de generalização do modelo proposto.

Tabela 1 – Características dos trabalhos levantados no estado da arte

| Trabalho | Célula FV | Pré-processamento | Aumento de Dados | Modelo proposto | Ajuste Fino |
|--------------------------------|-------------|-------------------|------------------|--------------------------|-------------|
| Et-taleby <i>et al.</i> (2022) | Si-m e Si-p | Não | Não | CNN + SVM | Não |
| Fan <i>et al.</i> (2022) | Si-p | Sim | Sim | CNN | Não |
| Tang <i>et al.</i> (2022) | Si-p | Sim | Não | CNN | Não |
| Demirci <i>et al.</i> (2021) | Si-m e Si-p | Não | Sim | k-NN, DT, RF, NB e L-CNN | Não |
| Acharya <i>et al.</i> (2021) | Si-m e Si-p | Sim | Não | DS-CNN | Não |
| Tang <i>et al.</i> (2020) | Si-m e Si-p | Não | Sim | CNN | Não |
| Mathias <i>et al.</i> (2020) | Si-p | Sim | Não | SVM e BPNN | Não |
| Deitsch <i>et al.</i> (2019) | Si-m e Si-p | Não | Sim | CNN e SVM | Não |
| Akram <i>et al.</i> (2019) | Si-m e Si-p | Não | Sim | CNN | Sim |
| Karimi <i>et al.</i> (2018) | Si-m e Si-p | Sim | Não | CNN e SVM | Não |

Fonte: Elaborado pelo autor (2024).

A Tabela 1 apresenta as técnicas utilizadas nos trabalhos relacionados ao estado da arte e que foram tomados como referências nesse trabalho. Verifica-se que a análise de defeitos através de imagens em EL de células de Si-m e Si-p estão sendo amplamente investigadas na literatura. Existe um balanceamento entre a utilização de técnicas de aumento de dados ao se implementar algoritmos de aprendizado profundo, tendo em vista que a quantidade de imagens de treinamento em um modelo de ML pode definir se o mesmo obterá ou não uma boa

capacidade de generalização. Por fim, verifica-se que as técnicas de ajuste fino para a obtenção dos hiperparâmetros ótimos das CNNs não foram investigadas em 9 dos 10 trabalhos relacionados apresentados, diante disso o método proposto neste trabalho combina o pré-processamento, e as técnicas de aumento de dados e ajuste fino na análise de defeitos em células FVs de Si-m e Si-p em imagens EL.

3 CÉLULAS FOTOVOLTAICAS E ELETROLUMINESCÊNCIA

3.1 Células Fotovoltaicas

A utilização de sistemas de geração de energia elétrica baseados na tecnologia FV tem como base o uso de módulos ou painéis FVs que são constituídos pela associação em série ou paralela de células FVs, tendo em vista a baixa tensão e corrente de saída em suas células (RIVAI *et al.*, 2019). Esses dispositivos desempenham um papel fundamental na aquisição de energia elétrica por meio do efeito FV convertendo diretamente a luz solar em eletricidade, sem a necessidade de partes móveis ou fontes de combustível.

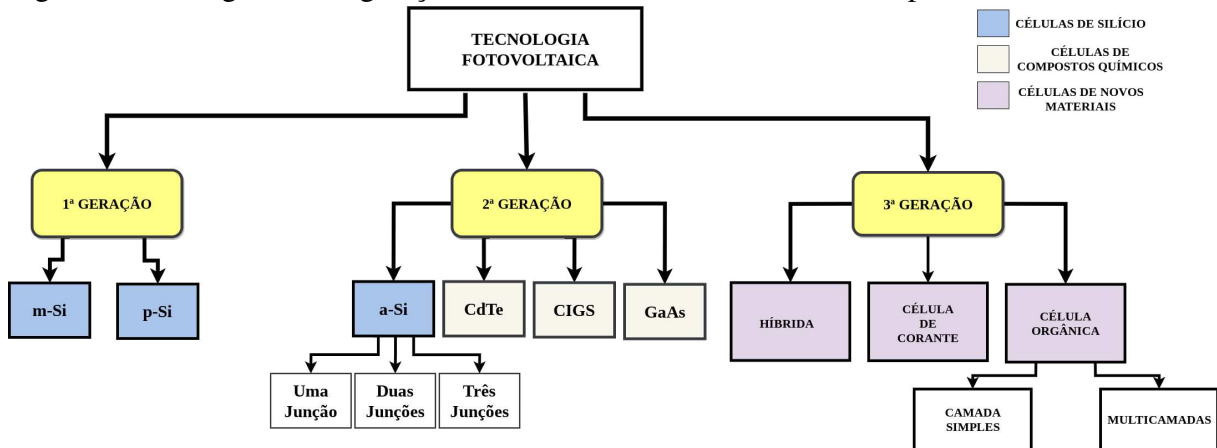
As células FVs de Si-m são fabricadas a partir de um único cristal de silício (Si), o que lhes confere uma estrutura altamente homogênea e eficiente. Essa técnica de fabricação resulta em células com maior eficiência de conversão da luz solar em eletricidade, chegando a valores próximos de 25% (Sánchez-Pacheco *et al.*, 2014). A pureza do material e a menor presença de defeitos nas células monocristalinas são responsáveis por esse rendimento. Ademais, tais células apresentam melhor desempenho em ambientes com baixa luminosidade, tornando-as ideais para aplicações em condições climáticas menos favoráveis. Por outro lado, as células de Si-p são produzidas a partir de múltiplos cristais de Si, resultando em uma estrutura menos homogênea se comparada às células monocristalinas. Isso implica em menor eficiência de conversão, geralmente em torno de 15% a 20%, devido à presença de mais defeitos e limitações na movimentação de elétrons. No entanto, as células policristalinas são mais fáceis e econômicas de serem produzidas em larga escala, reduzindo significativamente os custos de fabricação (RAPHAEL *et al.*, 2018).

Em relação aos custos, as células de Si-p apresentam uma vantagem considerável em relação às de Si-m. A fabricação de células monocristalinas requer um processo mais complexo e dispendioso, envolvendo técnicas de crescimento de cristais únicos em altas temperaturas. Esse processo resulta em um maior investimento inicial, refletindo diretamente no preço final dos painéis solares. Já as células policristalinas são mais acessíveis, o que torna essa tecnologia mais atrativa para a expansão do mercado FV em larga escala.

Com o desenvolvimento tecnológico, uma gama bastante ampla de materiais surgiu voltada à fabricação das células FVs. A Figura 1 classifica essas células de acordo com o tipo de material utilizado:

- A 1ª geração é composta pelas células oriundas de Si-m e Si-p e são os tipos mais utilizados

Figura 1 – Fluxograma das gerações de células fotovoltaicas e seus respectivos materiais.



Fonte: Elaborado pelo Autor (2024).

no mercado atualmente (RAPHAEL *et al.*, 2018).

- A 2ª geração de células FVs são produzidas utilizando-se materiais de filmes finos, como por exemplo: Telureto de Cádmio (CdTe), Silício Amorfo (Si-a), Arsenieto de Gálio (GaAs) e Cobre-Índio-Gálio-Selênio (CIGS).
- Já na 3ª geração contemplam-se as células com tecnologias recentes e as que se encontram em constante aperfeiçoamento, incluindo as células FVs do tipo multijunção, orgânicas, do inglês, *Organic Photovoltaic* (OPV) e as células sensibilizadas por corantes.

A Tabela 2 apresenta o rendimento médio de diferentes tipos de células FVs conforme a tecnologia empregada e exemplificada na Figura 1, distribuídas entre a primeira, segunda e terceira gerações (RAPHAEL *et al.*, 2018; ALEXANDRE *et al.*, 2018). As células de Si-m e Si-p, ambas da primeira geração, mostram um rendimento de 15% a 25% e 14% a 20%, respectivamente. Na segunda geração, as células de Si-a e as de CdTe apresentam menores rendimentos, variando de 6% a 9% e 9% a 16%, enquanto as células CIGS têm um rendimento ligeiramente superior, de 11,8% a 18,8%. Por fim, as tecnologias de terceira geração, como OPV e células sensibilizadas por corante, exibem rendimentos que variam de 12% a 18,2% e 10,7% a 11,9%, respectivamente.

3.2 Eletroluminescência em Células Fotovoltaicas

A avaliação da funcionalidade de sistemas FVs frequentemente envolve a inspeção de grandezas como corrente, tensão e potência. No entanto, alguns defeitos críticos, como pontos quentes (*hotspots*), microtrincas e fissuras, podem passar despercebidos quando se baseia apenas na análise das grandezas físicas do sistema. A pesquisa sobre a análise de defeitos em

Tabela 2 – Rendimento médio de células FVs de acordo com a tecnologia empregada.

| Tipo de célula | Geração | Rendimento |
|----------------|----------------|---------------|
| Si-m | 1 ^a | 15% a 25% |
| Si-p | 1 ^a | 14% a 20% |
| Si-a | 2 ^a | 6% a 9% |
| CdTe | 2 ^a | 9% a 16% |
| CIGS | 2 ^a | 11,8% a 18,8% |
| OPV | 3 ^a | 12% a 18,2% |
| Corante | 3 ^a | 10,7% a 11,9% |

Fonte: Adaptado de (ALEXANDRE *et al.*, 2018).


módulos e células FVs através de imagens tem sido amplamente explorada na literatura científica. Diversos métodos de detecção de falhas por meio de imagens termográficas em infravermelho foram propostos em estudos como (BUERHOP *et al.*, 2015), (VERGURA; MARINO, 2017), (BALASUBRAMANI *et al.*, 2020) e (MUTTILLO *et al.*, 2020). No entanto, é importante ressaltar que defeitos causados por trincas e microtrincas não podem ser efetivamente analisados através de imagens termográficas. Essa limitação tem impulsionado a busca por outras técnicas e abordagens para identificar e caracterizar esses defeitos, visando aprimorar a confiabilidade e a eficiência dos sistemas FVs.

A técnica EL emergiu como uma poderosa ferramenta para a análise de defeitos em células FVs. A EL é um fenômeno óptico que ocorre quando um material emite luz sob a influência de um campo elétrico. Em termos simples, é o processo inverso da fotogeração de eletricidade: ao invés da luz gerar corrente elétrica, é a corrente elétrica que gera luz. A técnica é especialmente útil para examinar e caracterizar células FVs, pois permite visualizar e identificar defeitos que não seriam facilmente detectados por outras técnicas convencionais (FRAZAO *et al.*, 2017).

A EL é baseada nos conceitos de recombinação de portadores de carga e emissão de fótons. Quando uma tensão elétrica é aplicada a uma célula FV, os portadores de carga (elétrons e lacunas) começam a se recombinar nas junções PN e na interface entre as camadas do dispositivo. Durante esse processo, a energia excedente é liberada na forma de fótons, resultando em emissão de luz visível e infravermelha (SOMBRIIO *et al.*, 2013). A imagem gerada por EL revela as variações espaciais na eficiência de conversão de luz em eletricidade, fornecendo informações valiosas sobre a qualidade e uniformidade das células solares.

A Figura 2(a) apresenta um exemplo de célula FV de Si-m funcional enquanto que a

Figura 2 – Imagens em eletroluminescência de células fotovoltaicas de silício: (a) monocristalino funcional. (b) monocristalino com defeito de ponto quente, trinca e microtrinca. (c) policristalino funcional. (d) policristalino com defeito de ponto quente e microtrinca.



Fonte: Elaborado pelo Autor (2024).

Figura 2(b) apresenta uma célula de Si-m não-funcional, ambas obtidas através da técnica EL. O mesmo ocorre para as células de Si-p apresentadas na Figura 2(c) e 2(d), respectivamente. Os defeitos presentes nas células FVs são perceptíveis e encontram-se em tons mais escuros. Entretanto, em uma inspeção visual de rotina em módulos FVs realizado por um especialista, não seria possível verificar a eficácia do módulo em grande parte dos problemas da célula.

4 PRÉ-PROCESSAMENTO

O pré-processamento de imagens é uma etapa fundamental no campo da visão computacional que tem como objetivo melhorar a qualidade, a clareza e a utilidade das imagens, tornando-as adequadas para a análise computacional (GONZALEZ; WOODS, 2010).

A etapa de pré-processamento de imagens envolve uma série de técnicas e operações que visam corrigir imperfeições, realçar características relevantes e reduzir ruídos indesejados. Várias etapas compõem esse processo, e a escolha das técnicas específicas depende do contexto da aplicação e das características das imagens em questão (WISMÜLLER *et al.*, 2000). No entanto, independentemente das técnicas utilizadas, o objetivo principal é preparar os dados visuais de forma que sejam adequados para análise por algoritmos de ML.

A correção de contraste e brilho são etapas de pré-processamento usualmente utilizadas (GONZALEZ; WOODS, 2010). Isso é essencial porque imagens capturadas sob diferentes condições de iluminação podem apresentar variações significativas em termos de contraste e brilho, conforme já ilustrado na Figura 2. A equalização de histograma, por exemplo, é uma técnica frequentemente empregada para melhorar o contraste, tornando os objetos de interesse mais distintos em relação ao fundo (MUSTAFA; KADER, 2018).

O pré-processamento de imagens é uma etapa crítica no *pipeline* de análise de imagens e no desenvolvimento de algoritmos de ML baseados em visão computacional. Uma abordagem cuidadosa e eficaz do pré-processamento pode melhorar significativamente a precisão e o desempenho desses algoritmos, permitindo que eles extraiam informações valiosas de dados visuais complexos.

4.1 Contrast Limited Adaptive Histogram Equalization (CLAHE)

Nas imagens em EL de células FVs, alguns defeitos como trincas e microtrincas podem ser difíceis de analisar e se diferenciar das trilhas presentes nas células FVs, conforme ilustrado na Figura 3. Uma das soluções possíveis para mitigar tal problema consiste na melhoria do contraste dessas imagens utilizando a técnica CLAHE (PIZER *et al.*, 1990) como uma variante da *Adaptive Histogram Equalization* (AHE) (KETCHAM *et al.*, 1974).

A AHE é uma técnica que, assim como o CLAHE, divide a imagem em pequenas regiões e aplica a equalização de histograma de forma independente em cada uma dessas regiões. Isso permite que detalhes em áreas de baixo contraste sejam realçados, pois a equalização é

adaptada às características locais da imagem (KETCHAM *et al.*, 1974). No entanto, um dos principais problemas do AHE é que ele pode amplificar significativamente o ruído em regiões homogêneas da imagem. Isso ocorre porque a equalização de histograma em áreas com pouca variação de intensidade pode resultar em um aumento exagerado do contraste do ruído presente.

Para resolver essa limitação, a técnica CLAHE foi desenvolvida melhorando o AHE ao introduzir um limite ao contraste em cada região, evitando que a amplificação do histograma aumente de forma excessiva. Especificamente, o CLAHE corta o histograma a um valor máximo antes de redistribuir os pixels, controlando assim a quantidade de contraste que é aplicado (PIZER *et al.*, 1990). Esse passo de limitação evita que o ruído seja intensificado, proporcionando uma imagem de maior qualidade e com melhor contraste nas áreas desejadas.

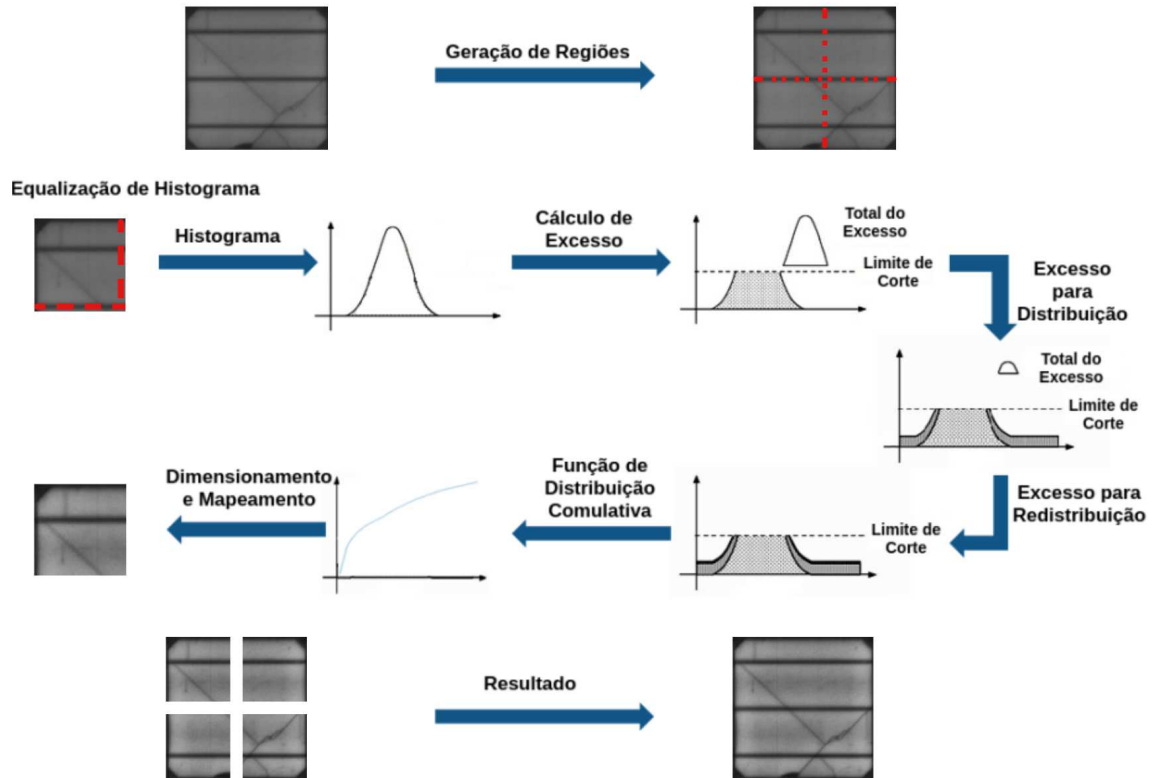
Ademais, o CLAHE realiza a interpolação entre as pequenas regiões para garantir transições suaves entre as regiões maiores, eliminando os limites visíveis que podem aparecer com o AHE. Isso resulta em uma imagem final mais uniforme e visualmente agradável, mantendo um bom equilíbrio entre realce de contraste e redução de ruído.

A imagem de entrada ilustrada na Figura 3 é dividida em múltiplas regiões. Em seguida, a equalização do histograma é aplicada a cada uma dessas regiões após definir um limite de corte específico. A equalização do histograma envolve várias etapas, a saber: cálculo do histograma e excesso, redistribuição do excesso, dimensionamento e mapeamento usando uma Função de Distribuição Cumulativa (FDC). Os valores do histograma que excedem o limite de corte são acumulados e redistribuídos em outros compartimentos. Depois disso, a FDC é calculada para os valores do histograma. Os valores de FDC de cada bloco são então dimensionados e mapeados conforme os valores de pixel da imagem original. Finalmente, as regiões processadas são reunidas para formar uma imagem de saída com contraste aprimorado (PIZER *et al.*, 1990; VIEIRA *et al.*, 2021a).

4.2 Aumento de Dados

Um dos grandes desafios ao se trabalhar com a análise de imagens em visão computacional são o número de amostras disponíveis para o treinamento e teste dos modelos de ML. O aumento de dados é uma técnica amplamente utilizada no campo do aprendizado profundo com o objetivo de melhorar a generalização de modelos preditivos. Esta técnica consiste em criar novas amostras de dados a partir das existentes, aplicando transformações que mantenham as características essenciais das informações originais, mas introduzam variações que permitam ao

Figura 3 – Representação da aplicação da técnica CLAHE em uma imagem de célula FV de Si-m.



Fonte: Adaptado de (VIEIRA *et al.*, 2021a).

modelo aprender de forma mais robusta (SHORTEN; KHOSHGOFTAAR, 2019).

A principal motivação para o uso de aumento de dados é mitigar o problema de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento e, portanto, apresenta um desempenho insatisfatório em dados não vistos anteriormente. Em contextos onde a quantidade de dados de treinamento é limitada, o aumento de dados torna-se crucial, pois permite que o modelo experimente uma maior diversidade de exemplos durante o treinamento, o que ajuda a capturar variações e nuances que podem estar presentes no conjunto de dados real, mas não suficientemente representadas no conjunto de dados de treinamento original (CUBUK *et al.*, 2018; SHORTEN; KHOSHGOFTAAR, 2019).

As técnicas de aumento de dados podem variar significativamente dependendo do tipo de dados com que se está lidando. Em imagens, transformações geométricas como rotações, translações, espelhamento horizontal e vertical, escalonamento e cortes (*cropping*) são usualmente utilizadas. Além disso, ajustes de cor, como modificação de brilho, contraste, saturação e balanço de cores, bem como a adição de ruído gaussiano ou outras formas de ruído, são frequentemente aplicadas (CUBUK *et al.*, 2018). Para dados textuais, a substituição de palavras por sinônimos, reescrita de sentenças, tradução reversa e modificações como inserção,

remoção ou permutação de palavras são estratégias comuns. Já no áudio, transformações temporais, adição de ruído de fundo e ajuste de volume são técnicas utilizadas para simular variações nos dados de áudio (CUBUK *et al.*, 2019).

Apesar dos benefícios, o aumento de dados não está isento de desafios e limitações. Transformações mal calibradas podem introduzir ruído ou distorções irrelevantes, prejudicando o aprendizado do modelo. Além disso, o aumento significativo do tamanho do conjunto de dados pode levar a maiores exigências computacionais e tempos de treinamento mais longos.

5 APRENDIZADO PROFUNDO

O aprendizado profundo emergiu como um ramo fundamental dentro da área de ML, abrindo novos caminhos para a inteligência artificial. O desenvolvimento e adoção de técnicas e algoritmos de ML avançados foram impulsionados pela crescente capacidade computacional, armazenamento rápido de dados e a habilidade de gerar recursos de alto nível por meio de otimização automática. A robustez dos modelos baseados em aprendizado profundo permitiu a implementação de redes neurais artificiais com múltiplas camadas de processamento. Como resultado, o aprendizado profundo tem atraído considerável interesse nos últimos anos, com diversas aplicações notáveis em áreas como reconhecimento facial (GUO; ZHANG, 2019), imagens médicas (ANAYA-ISAZA *et al.*, 2021) e detecção de falhas em módulos FVs (TANG *et al.*, 2022).

Neste capítulo será abordado os fundamentos teóricos sobre as CNNs na classificação de imagens e seus hiperparâmetros, assim como os conceitos de transferência de aprendizado, ajuste fino e sistemas genéticos evolutivos. Por fim, será abordado a teoria sobre o classificador SVM e as técnicas utilizadas neste trabalho para os experimentos de classificação.

5.1 Redes Neurais Convolucionais (CNNs)

As redes neurais artificiais passaram por uma notável evolução desde sua criação na década de 1940. McCulloch e Pitts (1943) introduziram o conceito de neurônios artificiais, enquanto o *Perceptron* de (ROSENBLATT, 1958) demonstrou sua aplicação na classificação linear durante a década de 1950. No entanto, as limitações dessas redes para tarefas complexas eram evidentes na década de 1960. Na década de 1980, inspirada na estrutura cortical do sistema visual humano, surgiu a proposta das CNNs por Fukushima (1980), que integram convoluções às redes neurais artificiais, revolucionando o processamento digital de imagens e o aprendizado profundo no campo da visão computacional. A incorporação do algoritmo de retropropagação foi feita por Waibel *et al.* (1989) e sua principal aplicação no princípio, dentro do contexto da visão, foi o reconhecimento automático de caracteres (DENKER *et al.*, 1988; LECUN *et al.*, 1989; LECUN *et al.*, 1998).

As CNNs são compostas usualmente por camadas de convolução, do inglês, *Convolution Layer* (CL), *pooling* e camada totalmente conectada, do inglês, *Fully Connected* (FC) (LECUN *et al.*, 1989). As CLs e camadas de *pooling* são responsáveis pela extração de caracterís-

ticas das imagens, antes das mesmas passarem pelo processo de classificação. Já as camadas FC, são responsáveis por mapear os recursos extraídos na saída final. Essa organização hierárquica de camadas em uma CNN permite que a rede aprenda representações progressivamente mais complexas dos dados, tornando-as extremamente eficazes em tarefas de visão computacional e em outros domínios onde o aprendizado de características relevantes é essencial.

5.1.1 Camada de Convolução

O bloco de construção mais importante de uma CNN é a CL. Nessa camada, a imagem de entrada (\mathbf{I}) é representada por uma matriz de pixels. A ideia da convolução é aplicar uma função ou *kernel* que percorre a matriz de pixels de \mathbf{I} através de passos, denominados *strides*. Durante esse processo, é realizado o produto entre cada elemento da matriz de \mathbf{I} e do *kernel* para obter o valor de saída. O resultado é então adicionado em uma posição correspondente ao mapa de características (ALZUBAIDI *et al.*, 2021; YAMASHITA *et al.*, 2018). Considerando \mathbf{I} como um sinal bidimensional, a convolução 2D é representada da seguinte forma:


$$(\mathbf{I} * g)[x, y] = \sum_{m_1=0}^{k_1-1} \sum_{m_2=0}^{k_2-1} \mathbf{I}[x + m_1, y + m_2] g[m_1, m_2], \quad (5.1)$$

em que a expressão $(\mathbf{I} * g)[x, y]$ denota o resultado da convolução na posição (x, y) da matriz de saída e g representa o filtro bidimensional que será aplicado à matriz de entrada \mathbf{I} . As variáveis m_1 e m_2 correspondem aos índices de deslocamento usados nas somas para percorrer todas as posições possíveis do filtro em relação à matriz de entrada, e k_1 e k_2 são as dimensões do filtro.

Para representar a operação convolucional de uma CL, considera-se o exemplo ilustrado na Figura 4 com uma matriz de pixels de tamanho (5×5) , que representa uma parte de uma imagem de entrada \mathbf{I} , juntamente com um *kernel* de tamanho (3×3) e *stride* igual a 1. O processo de convolução será realizado nove vezes sobre \mathbf{I} . Em cada etapa, o produto será calculado entre uma submatriz de dimensões (3×3) da matriz \mathbf{I} e o *kernel*. Essa abordagem ilustra o funcionamento da convolução em uma estrutura de camada convolucional.

O processamento de informações e a criação de representações significativas dependem diretamente da natureza dos filtros utilizados. O objetivo do treinamento nas camadas de convolução é estabelecer automaticamente os valores dos filtros com base no contexto do problema. Ademais, a quantidade de filtros, dimensão e técnica de preenchimento devem ser levadas em consideração durante a criação do modelo, pois o ajuste dos hiperparâmetros da rede

Figura 4 – Etapas da convolução em uma imagem **I** de (5×5) pixels com um filtro de tamanho (3×3) e *stride* igual a 1.




Fonte: Elaborado pelo Autor (2024).

irá refletir diretamente durante o treinamento e teste.

A Figura 5 ilustra o uso de operações de convolução aplicadas a uma célula FV de Si-m com defeitos de trincas. As operações de convolução foram realizadas utilizando três tipos diferentes de filtros, com o objetivo de realizar aguçamento e detecção de bordas horizontais e verticais na célula. Na primeira linha da imagem, a célula FV original passa pela etapa de convolução com um filtro de aguçamento, representado por uma matriz que realça os detalhes da imagem ao aumentar o contraste entre as regiões de interesse e o fundo. Esse processo enfatiza as trincas na célula, como mostrado na imagem resultante, onde as trincas aparecem mais destacadas, facilitando sua visualização. Na segunda linha, um filtro de detecção de bordas horizontais é aplicado à imagem original. Esse filtro é projetado para realçar as mudanças bruscas na intensidade dos pixels ao longo das linhas horizontais da imagem. O resultado é uma imagem onde as bordas horizontais são acentuadas, tornando-as mais visíveis e definidas. Por fim, na terceira linha, a célula FV é submetida a uma convolução com um filtro de detecção de bordas verticais enfatizando as mudanças de intensidade ao longo das colunas de pixels. A imagem resultante mostra as bordas verticais das trincas mais evidentes, o que auxilia na identificação de defeitos alinhados verticalmente na célula.

Figura 5 – Ajustamento, detecção de borda horizontal e vertical em uma célula fotovoltaica de silício monocristalino com defeitos de trincas.



Fonte: Elaborado pelo Autor (2024).

5.1.2 Camada de Pooling

A camada de *pooling* desempenha um papel crucial no contexto das CNNs, tendo como objetivo realizar a redução significativa do tamanho espacial dos mapas de características (*feature maps*). Essa redução é fundamental para minimizar o número de parâmetros a serem otimizados, resultando em uma considerável economia computacional durante o processo de treinamento e inferência da rede. Ao diminuir a dimensionalidade dos dados, a camada de *pooling* permite que a CNN processe informações mais rapidamente e seja mais eficiente em termos de memória.

Ademais, o processo de *pooling* contribui para o desenvolvimento de características mais invariantes a pequenas translações, rotações e deformações na imagem de entrada. Ao selecionar os valores mais representativos de uma determinada região, o *pooling* ajuda a concentrar-se em informações essenciais, como bordas, texturas e padrões, tornando a rede mais robusta a variações espaciais, o que é crucial em cenários de reconhecimento de objetos e classificação de imagens (ALZUBAIDI *et al.*, 2021). Outro aspecto importante é a capacidade do *pooling* de reduzir a probabilidade de *overfitting*. A redução da dimensionalidade limita a capacidade da CNN de memorizar os dados de treinamento, tornando-a menos suscetível a

aprender características específicas e ruidosas que podem não generalizar bem para novos dados. Isso melhora a capacidade da rede de generalizar e se adaptar a diferentes exemplos, resultando em um melhor desempenho em dados não vistos.

A camada de *pooling* pode ser implementada através de três passos, a saber: (i) escolha do tamanho da janela que irá percorrer a matriz de atributos; (ii) definição do número de *strides* em que o filtro irá percorrer a imagem e (iii) para cada janela, retornar o valor máximo, médio ou mínimo dos pixels obtidos. A Figura 6 ilustra a operação de *pooling* em uma matriz de atributos retornando os valores máximo, médio e mínimo de cada operação. Com uma janela de tamanho 2×2 e *stride* igual a 2, cada método é aplicado à matriz original para reduzir suas dimensões. O *pooling* máximo seleciona o maior valor em cada submatriz, o *pooling* médio calcula e retorna a média, e o mínimo escolhe o menor valor. Esse processo é essencial para reduzir a dimensionalidade e a complexidade da matriz, mantendo as características mais relevantes para a análise subsequente em CNNs.

Figura 6 – Representação da operação de *pooling* com valores máximo, médio e mínimo com uma janela de tamanho (2×2) e *stride* igual a 2.



Fonte: Elaborado pelo Autor (2024).

5.2 Hiperparâmetros

Os hiperparâmetros desempenham um papel crucial na configuração e no desempenho das arquiteturas de redes de aprendizado profundo. Esses, são parâmetros definidos antes do processo de treinamento e não são ajustados durante a aprendizagem. Entre os principais hiperparâmetros, destacam-se a taxa de aprendizado (*learning rate*), o tamanho do lote (*batch size*), o número de épocas (*epochs*) e parâmetros da arquitetura, como o número de camadas e neurônios por camada.

A taxa de aprendizado é um hiperparâmetro fundamental que controla o ajuste dos

pesos da rede em resposta ao gradiente do erro. Uma taxa de aprendizado alta pode acelerar o treinamento, mas corre o risco de não convergir ou de ultrapassar o ponto ótimo. Por outro lado, uma taxa de aprendizado muito baixa pode garantir a convergência, porém de forma muito lenta, aumentando significativamente o tempo de treinamento (MAI *et al.*, 2019). Ajustar corretamente a taxa de aprendizado é, portanto, essencial para o equilíbrio entre velocidade e precisão no treinamento.

O tamanho do lote refere-se ao número de amostras processadas antes da atualização dos pesos. O uso de pequenos lotes pode levar a uma maior variação nas atualizações dos pesos, o que pode ajudar a escapar de mínimos locais, mas também pode causar instabilidade no treinamento. Por outro lado, grandes lotes proporcionam uma estimativa mais estável do gradiente, mas exigem maior capacidade de memória e podem levar a uma menor generalização (MAI *et al.*, 2019). Encontrar o tamanho de lote adequado é, portanto, uma tarefa balanceada entre a eficiência computacional e a estabilidade do modelo.

A configuração da arquitetura da rede, incluindo o número de camadas e neurônios, é outro conjunto vital de hiperparâmetros. A escolha do número de camadas e número de neurônios por camada da rede impacta diretamente a capacidade do modelo de aprender e generalizar padrões complexos. Redes mais profundas podem capturar características mais abstratas, mas são mais propensas ao problema de gradientes desaparecentes ou explosivos. Redes com muitos neurônios podem aumentar a capacidade de aprendizado, mas correm o risco de *overfitting*, se não forem acompanhadas de técnicas adequadas de regularização (YOUNG *et al.*, 2015; MAI *et al.*, 2019).

5.3 Transferência de Aprendizado e Ajuste Fino

A transferência de aprendizado é uma técnica amplamente empregada no campo do aprendizado profundo envolvendo a utilização de um modelo previamente treinado em uma tarefa específica e sua adaptação para outra tarefa relacionada. Este método é especialmente valioso quando há uma quantidade limitada de dados disponíveis para a nova tarefa, uma vez que o modelo pré-treinado já possui um conhecimento embutido que pode ser aproveitado. A reutilização de modelos previamente treinados acelera o processo de treinamento e melhora a performance, tornando a transferência de aprendizado uma prática comum em várias aplicações em ML (LAKHANI, 2017).

A importância da transferência de aprendizado no aprendizado profundo se destaca

em diversos aspectos. Primeiramente, essa técnica permite que modelos complexos e robustos sejam desenvolvidos mesmo quando os recursos computacionais ou de dados são escassos. Ao invés de treinar um modelo do zero, que pode ser demorado e computacionalmente caro, é possível aproveitar os modelos já treinados em grandes conjuntos de dados, como por exemplo a ImageNet, que é um banco de dados com mais de um milhão de imagens e dez mil classes, economizando tempo e recursos. Isso é particularmente relevante em áreas como visão computacional e processamento de linguagem natural, onde modelos como as CNNs são frequentemente utilizados (MAYYA *et al.*, 2024).

Ademais, a transferência de aprendizado facilita a generalização dos modelos. Quando um modelo é treinado em uma tarefa relacionada, o mesmo aprende características e representações que são aplicáveis em diversas situações. Por exemplo, um modelo treinado para reconhecer objetos em imagens pode ser adaptado para a detecção de defeitos em células FVs em imagens EL (ET-TALEBY *et al.*, 2022). Essa capacidade de generalização é crucial para desenvolver sistemas de inteligência artificial que possam operar eficientemente em ambientes variados e lidar com dados que podem diferir dos dados de treinamento originais.

O ajuste fino em arquiteturas de redes de aprendizado profundo é um processo crucial para otimizar a performance de modelos pré-treinados em novas tarefas específicas. Esse procedimento envolve a adaptação de uma determinada topologia de rede já treinada em um grande conjunto de dados para uma tarefa particular, utilizando um conjunto de dados menor e mais específico. A prática do ajuste fino é amplamente utilizada em várias aplicações, como reconhecimento de imagem, processamento de linguagem natural e detecção de objetos, devido à sua eficácia em melhorar o desempenho do modelo sem a necessidade de treinar uma rede do zero (RAZAVIAN *et al.*, 2014).

O processo de ajuste fino pode ser abordado de várias maneiras, dependendo da quantidade de dados disponíveis e da similaridade entre as tarefas do conjunto de dados original e o novo conjunto de dados. Uma abordagem comum é congelar as camadas iniciais da rede, que capturam características mais gerais, e ajustar apenas as camadas finais, responsáveis por características mais específicas da tarefa-alvo (RAZAVIAN *et al.*, 2014). Essa técnica reduz o risco de *overfitting*, pois mantém a maior parte dos parâmetros treinados em um grande conjunto de dados, que são mais generalizáveis, enquanto permite ajustes nas partes da rede que têm maior impacto na tarefa específica.

Além do congelamento seletivo de camadas, a taxa de aprendizado é um parâmetro

crítico no ajuste fino. Taxas de aprendizado menores são frequentemente preferidas para evitar que os parâmetros da rede ajustados com grandes conjuntos de dados sejam drasticamente alterados, preservando o conhecimento previamente adquirido. Isso é especialmente importante quando os novos dados são limitados, uma vez que a rede precisa adaptar-se à nova tarefa sem esquecer o que aprendeu anteriormente (RAZAVIAN *et al.*, 2014; YOSINSKI *et al.*, 2014).

A seleção da arquitetura adequada para ajuste fino também desempenha um papel fundamental. Redes profundas com muitas camadas podem capturar características complexas e são adequadas para tarefas onde a granularidade dos dados é alta. Em contrapartida, arquiteturas mais simples podem ser suficientes para tarefas menos complexas, economizando tempo de treinamento e recursos computacionais. A arquitetura deve ser escolhida considerando-se a complexidade da tarefa, a quantidade de dados disponíveis e os recursos computacionais à disposição (YOSINSKI *et al.*, 2014).

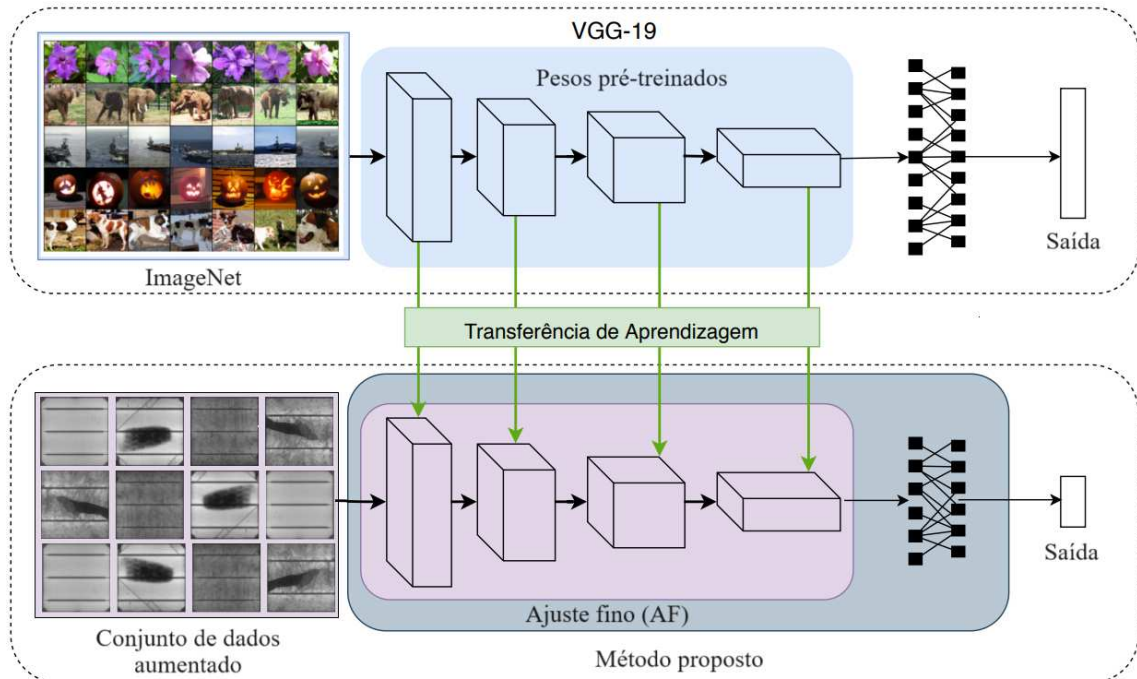
Ademais, a avaliação contínua do desempenho do modelo durante o ajuste fino é essencial. Métodos como validação cruzada podem ser utilizados para garantir que o modelo não esteja se sobreajustando aos dados de treinamento. Métricas como precisão, *recall*, *F1-score*, entre outras, devem ser monitoradas para assegurar que o modelo está se adaptando de forma eficaz à nova tarefa. Dessa forma, o ajuste fino não apenas melhora a performance do modelo, mas também garante que ele se mantenha robusto e generalizável. A Figura 7 representa as etapas de transferência de aprendizado e ajuste fino utilizando a base de dados ImageNet para um modelo de CNN na classificação de células FVs em funcionais e não-funcionais através de imagens EL.

5.4 Sistemas Genéticos Evolutivos

Os sistemas genéticos evolutivos representam uma classe de algoritmos de otimização e aprendizado inspirados nos processos de seleção natural e genética das populações biológicas. Estes sistemas são particularmente eficazes na resolução de problemas complexos onde as soluções não são facilmente deriváveis por métodos tradicionais devido à vastidão do espaço de busca ou à natureza intrincada das interações entre variáveis, baseando-se nos princípios fundamentais da teoria da evolução, conforme formulados por Charles Darwin. Estes princípios incluem a seleção natural, o cruzamento ou recombinação, a mutação e a sobrevivência dos mais aptos (WHITLEY *et al.*, 1996), conforme definido a seguir:

- **Seleção:** Este processo imita a competição por recursos e a sobrevivência dos mais aptos.

Figura 7 – Fluxograma exemplificando a transferência de aprendizagem e ajuste fino em um modelo de Rede Neural Convolutional.



Fonte: Adaptado de (VOGADO *et al.*, 2021).

Os indivíduos são avaliados através de uma função de aptidão, e aqueles com melhor desempenho têm maior probabilidade de serem selecionados para reprodução.

- **Cruzamento (Recombinação):** Duas ou mais soluções são combinadas para produzir uma ou mais soluções filhas. Este processo busca explorar novas áreas do espaço de busca, combinando características dos pais de maneira a potencialmente gerar indivíduos com melhor desempenho.
- **Mutação:** Alterações aleatórias são introduzidas nos indivíduos para manter a diversidade genética dentro da população e evitar a convergência prematura para ótimos locais.
- **Substituição:** Indivíduos menos aptos são substituídos pelos novos indivíduos gerados, garantindo que a população evolua ao longo do tempo.

Em um contexto computacional, essas ideias são traduzidas para operações específicas que manipulam uma população de indivíduos, cada um representando uma solução potencial para o problema em questão. Um sistema genético evolutivo típico inicia com uma população inicial de soluções candidatas geradas aleatoriamente. Cada indivíduo é representado por um cromossomo, que pode ser codificado de várias maneiras, como cadeias binárias, vetores de números reais, ou estruturas mais complexas como árvores ou grafos (WHITLEY *et al.*, 1996). Um dos exemplos mais conhecidos de sistemas genéticos evolutivos é o algoritmo genético em que o mesmo opera iterativamente sobre uma população de cromossomos, aplicando as operações

de seleção, cruzamento e mutação para criar uma nova geração de indivíduos. A aptidão de cada cromossomo é avaliada por uma função de aptidão específica ao problema (BENTLEY; CORNE, 2002).

Um algoritmo evolutivo mantém uma população de indivíduos $P(t) = \{x_1^t, \dots, x_n^t\}$ na iteração (geração) t . Cada indivíduo representa um candidato à solução do problema em questão e, em qualquer implementação computacional, assume a forma de alguma estrutura de dados S . Cada solução x_i^t é avaliada e produz alguma medida de adaptação, ou *fitness*. Então, uma nova população é formada na iteração $(t + 1)$ pela seleção dos indivíduos mais adaptados. Alguns indivíduos da população são submetidos a um processo de alteração por meio de operadores genéticos para formar novas soluções. Existem transformações unárias m_i (mutação) que criam novos indivíduos através de pequenas modificações de atributos em um indivíduo ($m_i : S \rightarrow S$), e transformações de ordem superior c_j (*crossover*), que criam novos indivíduos através da combinação de dois ou mais indivíduos ($c_j : S \times \dots \times S \rightarrow S$). Após um número de gerações, a condição de parada deve ser atendida, a qual geralmente indica a existência, na população, de um indivíduo que represente uma solução aceitável para o problema, ou quando o número máximo de gerações foi atingido (ZUBEN, 2009).

5.5 SVM

Embora não se trate de um algoritmo de aprendizado profundo a SVM (CORTES; VAPNIK, 1995) se caracteriza como um modelo de ML supervisionado sendo comumente utilizado em problemas de classificação e regressão. Esse modelo trabalha buscando um hiperplano ótimo que maximize a margem de separação entre diferentes classes em um espaço de características. Essa margem é definida pela distância entre o hiperplano e os pontos de dados mais próximos de qualquer classe, conhecidos como vetores de suporte (BISHOP, 2006).

A principal vantagem da SVM é sua capacidade de lidar eficientemente com dados de alta dimensionalidade e sua eficácia em situações onde a separação das classes não é linear, utilizando técnicas como a transformação de dados por meio de funções *kernel*. Os *kernels* permitem mapear dados para um espaço de características de maior dimensão onde uma separação linear é possível (BISHOP, 2006; CORTES; VAPNIK, 1995).

5.5.1 Forma linear

Para um conjunto de treinamento $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$, onde \mathbf{x}_i representa os vetores de entrada e y_i são os rótulos das classes, com $y_i \in \{-1, +1\}$, o objetivo é determinar um vetor de pesos \mathbf{w} e um termo de bias b que definam o hiperplano $\mathbf{w} \cdot \mathbf{x} + b = 0$. A forma primal do problema de otimização pode ser expressa como:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2, \quad (5.2)$$

sujeito às restrições:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad \forall i = 1, 2, \dots, n. \quad (5.3)$$

Essas restrições garantem que todos os pontos de dados sejam classificados corretamente com uma margem mínima de 1. O termo $\frac{1}{2} \|\mathbf{w}\|^2$ na função objetivo é utilizado para maximizar a margem de separação entre as classes. A margem é definida como a distância entre os vetores de suporte e o hiperplano de separação, e ao minimizar $\|\mathbf{w}\|$, maximiza-se a margem.

Para entender como o hiperplano separa as classes, considera-se que os pontos de dados mais próximos ao hiperplano são os vetores de suporte, que satisfazem a condição $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) = 1$.

5.5.2 Forma não-linear

A forma não-linear da SVM é uma reformulação do problema primal que é particularmente útil quando se trabalha com funções de *kernel*, permitindo a separação de dados não linearmente separáveis. Na forma dual, o problema é expressado em termos dos multiplicadores de Lagrange, α_i , associados às restrições do problema primal (BISHOP, 2006). Para um conjunto de treinamento $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$, o problema de otimização na forma dual é definido como:

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j), \quad (5.4)$$

sujeito às restrições:

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad \alpha_i \geq 0, \quad \forall i = 1, 2, \dots, n. \quad (5.5)$$

Os multiplicadores de Lagrange α_i indicam a importância de cada ponto de treinamento na determinação do hiperplano de separação. Apenas os pontos de dados que possuem $\alpha_i > 0$ são os vetores de suporte, pois são esses pontos que definem a posição do hiperplano. O vetor de pesos \mathbf{w} do hiperplano na forma linear pode ser expresso em termos dos α_i da seguinte forma:

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i, \quad (5.6)$$

o termo de bias b pode ser determinado utilizando qualquer vetor de suporte (\mathbf{x}_k, y_k) :

$$b = y_k - \sum_{i=1}^n \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}_k). \quad (5.7)$$

Na prática, ao utilizar funções de *kernel* $K(\mathbf{x}_i, \mathbf{x}_j)$, que substituem o produto interno $\mathbf{x}_i \cdot \mathbf{x}_j$, a SVM pode realizar separações não lineares. O problema de otimização na forma não-linear, usando o *kernel*, é escrito como:

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j), \quad (5.8)$$

o vetor de pesos na forma não-linear é então definido implicitamente pelos vetores de suporte e pelo *kernel* da seguinte forma:

$$f(\mathbf{x}) = \sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b. \quad (5.9)$$

5.6 Validação do Modelo

A implementação de diversos algoritmos de classificação em aprendizado profundo requer a existência de um mecanismo adequado para sua avaliação. Para garantir a eficácia e a fidelidade na avaliação das características de cada algoritmo, torna-se imprescindível o cuidado na seleção das amostras utilizadas tanto para o treinamento quanto para o teste do classificador.

A avaliação do desempenho do modelo proposto foi realizada através da validação cruzada *k-fold* (KOHA., 1995) utilizando 5 *folds* ($k = 5$). A utilização da validação cruzada em algoritmos de aprendizado profundo é de extrema importância para a obtenção de resultados confiáveis e robustos. Essa abordagem permite a avaliação do desempenho do modelo em diferentes

conjuntos de dados, reduzindo o impacto de possíveis variações nos dados de treinamento e teste. Ademais, a validação cruzada possibilita uma melhor estimativa do desempenho do modelo em dados não vistos, tornando-o mais generalizável.

No problema de classificação binária proposto neste trabalho a avaliação do conjunto de teste está dividida em quatro possibilidades, a saber: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN), onde:

- **VP**: Representa uma imagem de célula FV funcional classificada corretamente.
- **VN**: Representa uma imagem de célula FV não-funcional classificada corretamente.
- **FP**: Representa uma imagem de célula FV não-funcional classificada como funcional.
- **FN**: Representa uma imagem de célula FV funcional classificada como não-funcional.

O índice *Kappa* (κ) é uma medida estatística utilizada para avaliar a concordância entre dois avaliadores ou métodos de classificação que atribuem categorias a um conjunto de itens (COHEN; KAPPA, 1968). Ao contrário das medidas simples de concordância, como a porcentagem de concordância, o índice *Kappa* considera a concordância que ocorre ao acaso, sendo especialmente relevante em estudos de confiabilidade interavaliador e validação de testes diagnósticos (FLEISS; COHEN, 1973). O índice *Kappa* é calculado na forma abaixo:

$$\kappa = \frac{P_o - P_e}{1 - P_e} = 1 - \frac{1 - P_o}{1 - P_e}, \quad (5.10)$$

onde P_o é a concordância relativa observada entre os avaliadores, definida por:

$$P_o = \frac{VP + VN}{VP + VN + FP + FN}, \quad (5.11)$$

e P_e é a probabilidade hipotética de concordância ao acaso, usando os dados observados para calcular as probabilidades de cada observador ver aleatoriamente cada categoria, conforme apresentado a seguir:

$$P_e = \left(\frac{(VP + FN) \times (VP + FP)}{(VP + VN + FP + FN)^2} \right) + \left(\frac{(VN + FP) \times (VN + FN)}{(VP + VN + FP + FN)^2} \right). \quad (5.12)$$

Na Tabela 3 o índice *Kappa* é dividido em faixas que vão de Nenhum a Quase Perfeito, associando cada faixa a um nível de concordância e à porcentagem de dados considerados confiáveis. Valores de *Kappa* entre 0 e 20 indicam uma concordância nula, enquanto valores

Tabela 3 – Concordância do índice *Kappa*.

| Valor de <i>Kappa</i> | Nível de Concordância | % de dados que são confiáveis |
|-----------------------|-----------------------|-------------------------------|
| 0-20 | Nenhum | 0-4% |
| 21-39 | Mínimo | 4-15% |
| 40-59 | Fraco | 15-35% |
| 60-79 | Moderado | 35-63% |
| 80-90 | Forte | 64-81% |
| Acima 90 | Quase Perfeito | 82-100% |

Fonte: Adaptado de (MCHUGH, 2012).

acima de 90 são interpretados como quase perfeitos, refletindo alta confiabilidade (MCHUGH, 2012).

A Acurácia (A_{cc}) avalia o quão efetivo o modelo é, por meio da probabilidade do algoritmo realizar previsões corretas (STORY; CONGALTON, 1985). O resultado dessa avaliação são valores entre 0 e 1 e é representada abaixo:

$$A_{cc} = \frac{VP + VN}{VP + VN + FP + FN}. \quad (5.13)$$

A Sensibilidade (S_s) também conhecido como revocação ou *recall* estima a probabilidade de um exemplo pertencente à classe positiva ser predito como positivo e pode ser representada na forma abaixo:

$$S_s = \frac{VP}{VP + FN}. \quad (5.14)$$

A Precisão (P) estima a probabilidade da predição positiva estar correta (FACELI *et al.*, 2011) e é representada por:

$$P = \frac{VP}{VP + FP}. \quad (5.15)$$

A Especificidade (E) estima a probabilidade de um exemplo pertencente à classe negativa ser predito corretamente como negativo e é dada por:

$$E = \frac{VN}{VN + FP}. \quad (5.16)$$

Por fim, através da combinação de (5.14) e (5.15), pode-se obter a medida *F-score*, no qual realiza uma combinação balanceada dessas duas medidas. Essa métrica é especialmente útil quando há um desequilíbrio entre as classes do problema, pois leva em conta tanto os FP quanto os FN, fornecendo uma visão mais completa do desempenho do modelo. Essa métrica é representada por:

$$F - score = \frac{(2 \times P \times S_s)}{(P + S_s)} = \frac{2VP}{VP + FP + FN}. \quad (5.17)$$

6 METODOLOGIA

Neste capítulo é apresentada a metodologia empregada na classificação de defeitos das células FVs em funcionais e não-funcionais. Será detalhado o conjunto de imagens utilizado neste trabalho, assim como as técnicas de aumento de dados a fim de aumentar as variações das imagens da base de dados. Apresenta-se também o pré-processamento empregado para melhorar as características importantes das imagens das células FVs, o método de ajuste fino para melhorar os resultados da extração de características realizada pelo modelo de CNN implementado, a busca otimizada por um conjunto ótimo de hiperparâmetros no ajuste fino, e por fim, a HCNN utilizada no trabalho.

6.1 Base de Imagens


Neste trabalho, utilizou-se o conjunto de imagens *Electroluminescence Photovoltaic Dataset* (ELPV)¹ disponibilizada por (BUERHOP-LUTZ *et al.*, 2018; DEITSCH *et al.*, 2019; DEITSCH *et al.*, 2021). A base contém 2.624 imagens de 300×300 pixels em EL de células FVs, sendo 1.074 de Si-m, das quais 500 imagens são funcionais e 574 não-funcionais e 1.550 de Si-p, das quais 770 são funcionais e 780 não-funcionais, todas retiradas de 44 módulos FVs. Ademais, as imagens foram normalizadas em contraste e perspectiva, padronizadas em níveis de cinza e dimensão. A Figura 8 exibe diferentes estados de células FVs de Si-m e Si-p, capturadas por EL, ilustrando a comparação entre células funcionais e não-funcionais. As células de Si-m ilustradas na Figura 8(a) e 8(b) apresentam desde um estado funcional até defeitos como trincas e microtrincas. As células de Si-p ilustradas na Figura 8(c) e 8(d) mostram uma progressão de defeitos, incluindo rachaduras, trincas e delaminação, evidenciando a degradação severa do material.

6.2 Aumento de Dados

Ao se trabalhar com algoritmos de aprendizado profundo, mais especificamente com problemas que envolvem análise de imagens, técnicas de aumento de dados se fazem necessárias para melhorar a quantidade de amostras disponíveis para o treinamento das redes (CHLAP *et al.*, 2021). Entretanto, deve-se compreender quais técnicas melhor se encaixam ao problema, e quais os intervalos de seus parâmetros são aceitáveis. Logo, conhecer bem a problemática que se

¹ <https://github.com/zae-bayern/elpv-dataset>

Figura 8 – Imagens em eletroluminescência de células fotovoltaicas de silício: (a) monocristalino funcional. (b) monocristalino com defeitos de trincas e microtrincas. (c) policristalino funcional. (d) policristalino com defeito de rachadura, trincas e delaminação.



Fonte: Elaborado pelo Autor (2024).


deseja resolver e realizar um estudo das imagens resultantes desse processo se torna primordial. Ao aplicar técnicas de aumento de dados simples de forma aleatória, é possível gerar um número maior de amostras de imagens sem resultados repetidos, já que cada imagem poderá gerar k novas imagens, estando essa quantidade limitada somente ao número de funções de aumento e o intervalo de seus parâmetros (CUBUK *et al.*, 2019).

Neste trabalho, foram empregadas quatro técnicas de aumento de dados, a saber: 1) rotação das imagens, variando os graus em 90° no sentido horário e anti-horário. Esses valores foram selecionados visando preservar as características originais da imagem. 2) espelhamento (*flipping*); 3) borrramento e 4) aumento do brilho em 20%. As técnicas 1) e 2) foram realizadas sem a ajuda de qualquer *software*, ou seja, as novas imagens foram geradas de forma *offline*. Já as técnicas 3) e 4) foram implementadas por meio da biblioteca Python *Albumentations*² (BUSLAEV *et al.*, 2020). O conjunto de dados resultante passou a ter 13.120 imagens de células FVs, mantendo-se a proporção original das células funcionais e não-funcionais. A Figura 9 exibe os resultados de diferentes técnicas de aumento de dados aplicadas na base. A imagem original ilustrada na Figura 9(a) passa por diversas transformações: rotação em 90° no sentido horário 9(b), rotação em 90° no sentido anti-horário 9(c), espelhamento 9(d), borrramento 9(e) e aumento de brilho em 20% 9(f).

Com as técnicas de aumento de dados empregadas, foi possível apresentar aos

² <https://github.com/albumentations-team/albumentations>

Figura 9 – Resultado das técnicas de aumento de dados empregadas na base de imagens. (a) Original. (b) Rotação em 90° no sentido horário. (c) Rotação em 90° no sentido anti-horário. (d) Espelhamento (*flipping*). (e) Borrramento e (f) Aumento do brilho em 20%.



Fonte: Elaborado pelo Autor (2024).

modelos de aprendizado profundo diferentes imagens de células FVs. De acordo com as Figuras 8(a) e 8(b), observa-se que algumas imagens de células apresentam duas ou três estruturas horizontais que as dividem em três ou quatro regiões. Denominadas de *busbars*, essas estruturas são filamentos metálicos que servem para realizar a condução dos elétrons através das células que formam o módulo FV. Logo, com o aumento de dados, algumas imagens que possuem *busbars* na horizontal são apresentadas com os filamentos na vertical, conforme ilustrado nas Figuras 9(b) e 9(c), criando um conjunto de treinamento mais representativo das variações encontradas em cenários do mundo real.

6.3 Pré-processamento com *CLAHE*

O *CLAHE* é utilizado em contextos onde o contraste é baixo e a distribuição de intensidade de pixel é não homogênea. Este método é particularmente eficaz em imagens EL de células FVs de Si-m e Si-p, que são cruciais para a detecção de defeitos e a avaliação da eficiência do dispositivo (VIEIRA *et al.*, 2021a).

As imagens EL são obtidas aplicando-se uma corrente direta através da célula FV e capturando a luz emitida devido à recombinação de pares elétron-buraco. No entanto, essas imagens frequentemente apresentam baixo contraste devido à distribuição desigual da

luminescência, influenciada por defeitos internos, variações na dopagem e irregularidades na superfície das células (BALASUBRAMANI *et al.*, 2020). Essas características podem dificultar a identificação precisa de áreas defeituosas e a avaliação da qualidade do material.

A aplicação do CLAHE em imagens EL envolve a divisão da imagem em pequenas regiões denominadas *tiles*. Em cada *tile*, é realizada a equalização do histograma, o que ajusta a distribuição dos níveis de cinza, aumentando o contraste local de forma controlada para evitar amplificação excessiva do ruído. Um limite de contraste é estabelecido para restringir a amplificação de regiões de alto contraste, prevenindo o surgimento de artefatos que podem obscurecer informações importantes.

Para células de Si-m, a estrutura cristalina uniforme resulta em uma resposta mais homogênea à excitação EL, conforme ilustrado na Figura 8(a) e 8(b). No entanto, defeitos pontuais como desordens cristalinas ou contaminações podem causar variações locais na luminescência (MUTTILLO *et al.*, 2020). O CLAHE pode acentuar essas variações, tornando os defeitos mais evidentes e permitindo uma análise detalhada da qualidade cristalina e da eficiência da recombinação.

Em células de silício Si-p, a presença de múltiplos grãos com orientações e tamanhos variados resulta em uma resposta EL intrinsecamente mais heterogênea, conforme ilustrado na Figura 8(c) e 8(d). As fronteiras de grão, por exemplo, são regiões de recombinação não radiativa que aparecem como áreas de menor luminescência. O CLAHE pode melhorar a visibilidade dessas fronteiras, facilitando a análise da estrutura granular e a identificação de defeitos como trincas e inclusões que impactam a performance do dispositivo.

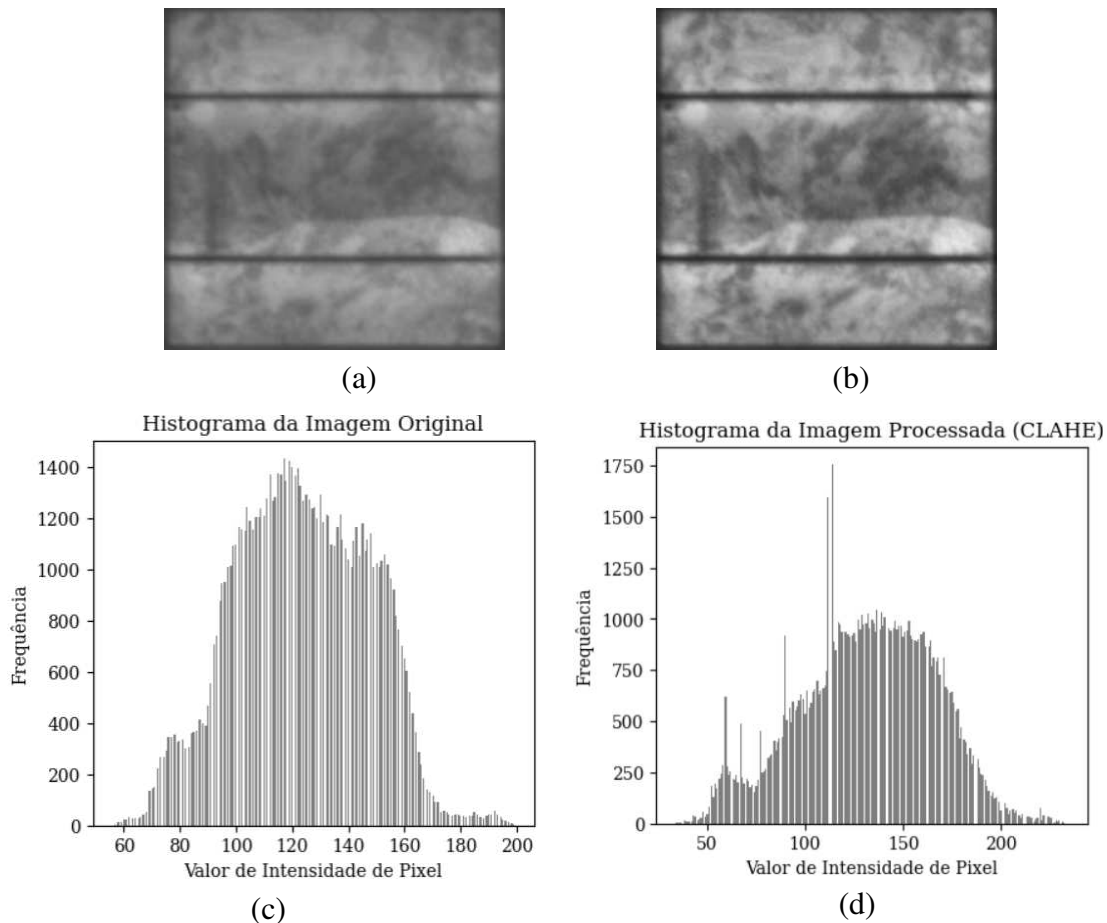
Ademais, o CLAHE pode ser ajustado para diferentes parâmetros, como o tamanho dos *tiles* e o limite de contraste, permitindo a otimização do processamento de acordo com as características específicas da imagem e os requisitos da análise.

Após o aumento de dados, todas as imagens foram pré-processadas por meio da técnica CLAHE, utilizando a biblioteca Python *Albumentations* (BUSLAEV *et al.*, 2020). Foi definido a dimensão dos blocos em 8×8 pixels. A escolha de áreas menores ocorreu por reduzir as chances de proliferação de ruídos. Porém, quando o ruído é encontrado, é aplicado o limite de corte com fator padrão equivalente a 2. Desse modo, se em qualquer compartimento do histograma for encontrado um ruído acima do fator de corte especificado, esses ruídos são removidos e distribuídos antes da equalização do histograma. Cada bloco foi processado individualmente para a equalização do histograma, e a transformação foi garantida para ser

aplicada a todas as imagens da base de dados aumentada.

A Figura 10(a) ilustra um exemplo de imagem de célula FV de Si-p, enquanto que a Figura 10(b) apresenta o resultado da aplicação da técnica CLAHE durante a etapa de pré-processamento. Para verificar a eficácia da técnica CLAHE no conjunto de dados, foram gerados os histogramas da intensidade dos pixels das imagens.

Figura 10 – (a) Imagem original da célula fotovoltaica de silício policristalino. (b) Imagem resultante da aplicação da técnica CLAHE. (c) Histograma da intensidade dos pixels da imagem original. (d) Histograma da intensidade dos pixels após a aplicação da técnica CLAHE.



Fonte: Elaborado pelo Autor (2024).

A análise dos histogramas de intensidade de pixel das Figuras 10(c) e 10(d) revela as mudanças significativas após a aplicação da técnica CLAHE. Na imagem original, o histograma mostra uma concentração de valores de pixel em uma faixa estreita de intensidades, o que indica baixo contraste. Esta limitação no contraste implica que muitos detalhes sutis da imagem podem não ser visíveis, dificultando a identificação de defeitos e irregularidades nas células FVs.

Já o histograma da imagem processada pelo CLAHE exibe uma distribuição mais uniforme das intensidades de pixel. Essa redistribuição indica um aumento significativo no

contraste da imagem. Com os valores de pixel mais dispersos por toda a faixa de intensidades, os detalhes anteriormente obscurecidos tornam-se mais visíveis. A técnica CLAHE consegue realçar essas características, melhorando a visibilidade e a qualidade da imagem.

6.4 Ajuste Fino Genético

A escolha dos hiperparâmetros de uma CNN é uma etapa importante do ajuste fino, já que encontrar um conjunto que possa garantir uma boa taxa de convergência é uma tarefa complexa devido seu grande espaço de busca. Na literatura, cada vez mais usuários lutam para configurar hiperparâmetros, e uma parte substancial do tempo é gasta ajustando-os empiricamente. Ademais, em muitos casos os hiperparâmetros dos modelos de CNNs empregados não são explorados à fundo, ocasionando uma redução da precisão e aumento do custo computacional envolvido (DEITSCH *et al.*, 2019; MATHIAS *et al.*, 2020; ACHARYA *et al.*, 2021). O Ajuste Fino Genético (AFG) em topologias de CNNs é uma técnica poderosa para a otimização de hiperparâmetros que visa encontrar a configuração ideal de modelo para tarefas específicas (MAI *et al.*, 2019).

O AFG utiliza algoritmo genético para otimizar os hiperparâmetros de uma CNN. Os algoritmos genéticos são inspirados pelo processo de evolução natural e utilizam operações como seleção, cruzamento (*crossover*) e mutação para evoluir soluções ao longo de várias gerações (EIBEN; SMITH, 2015). Os hiperparâmetros de uma CNN, como a profundidade da rede, o número de filtros em cada camada convolucional, o tamanho do filtro, a taxa de aprendizado, o tipo de função de ativação, entre outros, são codificados como genes em um cromossomo em que cada cromossomo representa uma configuração única da CNN.

Para melhor compreensão do processo de seleção evolutiva do AFG, foram utilizadas as etapas propostas no trabalho de Vieira *et al.* (2021a), Vieira *et al.* (2021b), Vieira *et al.* (2021c) em que:

- **Indivíduo:** É uma CNN pré-treinada com ImageNet (ResNet50 e VGG16), cujos hiperparâmetros estão contidos em um vetor de atributos que informa a quantidade de camadas, número de neurônios por camada, função de ativação, otimizador, etc.
- **População inicial:** Foram criadas uma população inicial de 50 indivíduos, tendo em vista que o valor escolhido permite uma boa amostragem inicial de indivíduos, todos gerados aleatoriamente e sem duplicações.
- **Reprodução:** Foram selecionados dois indivíduos através de uma roleta conhecida como

amostragem de substituição estocástica (MELLO; BAYRAKSAN, 2014). Cada indivíduo é escolhido com base em sua aptidão para resolver o problema.

- **Novo indivíduo:** Em cada reprodução, um novo indivíduo é gerado, herdando características tanto do pai quanto da mãe em um processo chamado *crossover*.
- **Mutação:** Sempre que um novo indivíduo é gerado pelo *crossover*, a mutação pode alterar um genótipo em seu vetor de atributos (um hiperparâmetro). A probabilidade de mutação neste trabalho é de 7%, um valor que não é muito alto para impedir a transmissão de características dos pais, nem tão baixo a ponto de impedir o surgimento de novas características.
- **Seleção de indivíduos para nova geração:** Ao final de cada geração, 60% dos indivíduos com melhor *Kappa* são selecionados e os demais descartados. Essa seleção permite encontrar as melhores características para resolver o problema. Os indivíduos selecionados terão uma nova chance de reproduzir e transmitir suas características para as próximas gerações.
- **Condição de parada:** Para evitar *loops* infinitos, foram estabelecidos três condições de parada: 1) se qualquer indivíduo atingir 100% de *Kappa*, o algoritmo deve parar, pois seria impossível obter resultados melhores; 2) a partir da 10ª geração, compara-se a precisão média da geração atual com as 5 anteriores, se o resultado for inferior, o algoritmo deve parar, dando tempo suficiente para desenvolver bons resultados sem interrupções e permitir progressão; 3) se a centésima geração for alcançada, o algoritmo deve parar, pois consideramos tempo suficiente para atingir um ótimo global ou estagnar o aprendizado em um ótimo local.

Até o momento, a utilização de AFG para otimização de CNNs, especificamente para a extração de características e classificação de defeitos em células FVs de Si-m e Si-p, ainda não foi amplamente explorada na literatura, conforme os trabalhos apresentados na Tabela 1, representando uma oportunidade de investigação significativa na área, combinando técnicas avançadas de ML com algoritmos inspirados pela natureza para resolver um problema de alta relevância industrial. Ao utilizar CNNs como extratores de características, seguidas de uma SVM para a classificação, a metodologia proposta pode melhorar a precisão da detecção de defeitos. As CNNs podem aprender representações ricas e discriminativas das imagens, enquanto a SVM pode atuar como um classificador robusto, especialmente eficaz em problemas com conjuntos de dados menores ou desequilibrados.

6.5 Espaço de Busca dos Hiperparâmetros

Para otimizar o processo de classificação de defeitos em células FVs de Si-m e Si-p, foi necessário um cuidadoso delineamento do espaço de busca dos hiperparâmetros. Na Tabela 4, apresenta-se os tipos de hiperparâmetros, suas possíveis configurações e quantidades.

Tabela 4 – Espaço de pesquisa de hiperparâmetros: Tipos de hiperparâmetros, suas possibilidades e quantidades.

| Tipo de hiperparâmetros | Possibilidades |
|-------------------------|--------------------------------------|
| CNN | {ResNet50, VGG16} |
| Nº de camadas | {1, 2} |
| Neurônios/Camada 1 | {512, 768, 1024} |
| Neurônios/Camada 2 | {64, 128, 256, 512, 768, 1024} |
| Função de ativação | {tanh, relu, selu, elu, exponential} |
| Tipo de otimizador | {adam, sgd, rmsprop, adadelta} |
| <i>Dropout</i> | {30%, 40%, 50%, 60%} |

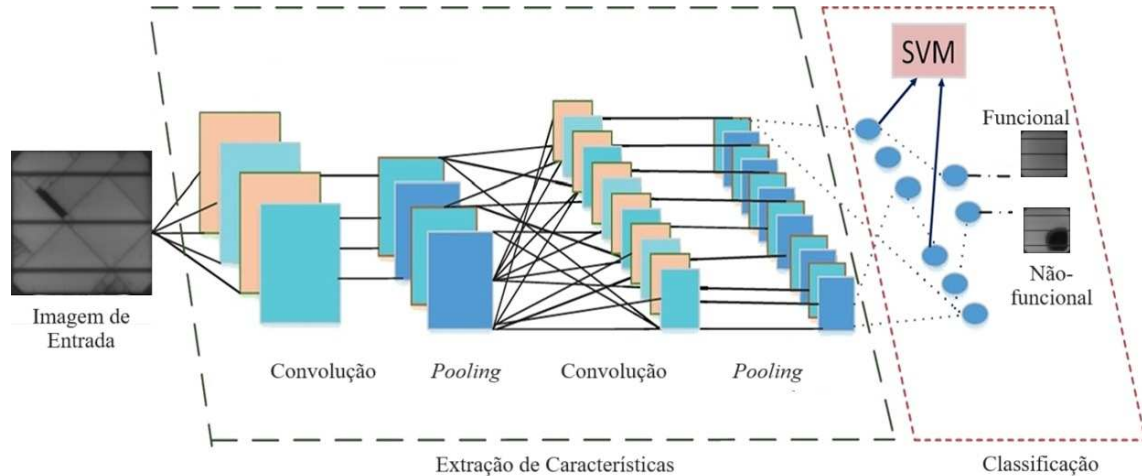
Fonte: Elaborado pelo Autor (2024).

Optou-se por utilizar as arquiteturas ResNet50 e VGG16 como as bases das CNNs. Ambas são redes bem estabelecidas e reconhecidas por sua alta performance em tarefas de classificação de imagens, pré-treinadas com a base ImageNet. A escolha dessas arquiteturas oferece um equilíbrio entre profundidade e simplicidade estrutural, facilitando a adaptação para novas tarefas de classificação.

Para o número de camadas, se limitou a variação entre 1 e 2, visando manter um modelo relativamente simples e evitar *overfitting*, uma vez que o problema investigado está focado em células FVs. A quantidade de neurônios por camada foi ajustada para refletir a necessidade de complexidade crescente conforme a rede se aprofunda. Para a primeira camada, os valores escolhidos foram 512, 768 e 1.024, proporcionando uma diversidade suficiente para capturar características complexas das imagens. Para a segunda camada, a variedade é maior, com opções de 64, 128, 256, 512, 768 e 1.024 neurônios, permitindo flexibilidade na modelagem da rede e no ajuste fino das representações aprendidas.

As funções de ativação incluídas no espaço de busca são: *tanh*, *relu*, *selu*, *elu* e *exponential*. Cada uma dessas funções tem características específicas que podem influenciar a

Figura 11 – Modelo de Rede Neural Convolutiva Híbrida para Classificação de Defeitos de Células Fotovoltaicas em Funcionais e Não-funcionais.



Fonte: Elaborado pelo Autor (2024).

performance do modelo, desde a capacidade de introduzir não-linearidades até a habilidade de lidar com o problema do desvanecimento do gradiente. Os otimizadores escolhidos: *adam*, *sgd*, *rmsprop* e *adadelta*, são bem estabelecidos e amplamente utilizados em treinamento de redes neurais. A diversidade de otimizadores permite explorar diferentes abordagens na atualização dos pesos da rede, impactando na velocidade de convergência e na qualidade final do modelo.

Por fim, as taxas de *dropout* de 30%, 40%, 50% e 60% foram incluídas para prevenir *overfitting*, adicionando uma forma de regularização que ajuda a melhorar a generalização do modelo.

6.6 HCNN

A construção da HCNN para a classificação de defeitos em células FVs proposta neste trabalho combinou a robustez das CNNs na extração de características com a precisão da SVM na classificação. O processo envolve três etapas principais, a saber: AFG, definição do espaço de busca dos hiperparâmetros e configuração dos parâmetros da SVM. A Figura 11 ilustra um modelo padrão de HCNN para a classificação de defeitos em células FVs.

6.6.1 Extração de Características

A HCNN proposta se destaca ao utilizar modelos pré-treinados, como ResNet50 e VGG16, que são especializados na extração de atributos complexos de imagens de células FVs. Esses modelos são capazes de identificar padrões intrínsecos nas imagens que são fundamentais

para distinguir entre células funcionais e não-funcionais.

Após a etapa de obtenção dos hiperparâmetros das redes por meio do AFG, as redes ResNet50 e VGG16 pré-treinadas são aplicadas às imagens EL de células FVs, onde cada camada convolucional extrai diferentes níveis de características, desde bordas simples até padrões mais abstratos, que são específicos para a detecção de defeitos em células FVs. A vantagem de utilizar redes pré-treinadas está na capacidade dessas redes em reutilizar o conhecimento adquirido em tarefas anteriores, o que acelera o processo de treinamento e aumenta a precisão da extração de características.

Após a extração das características, a SVM é empregada como o classificador final. Diferente de classificadores comuns que utilizam a camada densa final de uma CNN, a HCNN utiliza a SVM para substituir a camada totalmente conectada, tendo em vista à sua capacidade de lidar eficientemente com conjuntos de dados com muitas dimensões e de encontrar o hiperplano de separação ótimo entre as classes. No caso das células FVs, a SVM é treinada para classificar as células em funcionais e não-funcionais, baseando-se nos atributos extraídos pela CNN.

A combinação entre os modelos de CNN e SVM é particularmente poderosa neste contexto, pois a CNN realiza a redução da dimensionalidade e a abstração das características relevantes, enquanto a SVM se foca na maximização das margens de separação entre as classes. Isso resulta em um modelo robusto, capaz de lidar com a variabilidade presente nas imagens de células FVs e com a dificuldade de distinguir entre defeitos sutis e as características normais das células. Além disso, o uso de algoritmos genéticos para a otimização dos hiperparâmetros da HCNN permite que o modelo seja ajustado de forma precisa às especificidades do conjunto de dados utilizado, melhorando ainda mais seu desempenho.

6.6.2 Configuração da SVM

A SVM é um método de classificação eficiente, especialmente em cenários com alta dimensionalidade de dados, como é o caso das características extraídas pelas CNNs na HCNN. A configuração dos parâmetros da SVM é crucial para garantir que o modelo atinja seu desempenho máximo.

O primeiro parâmetro de importância na configuração da SVM é o tipo de *kernel*. No contexto deste trabalho, utilizou-se o *kernel radial basis function*, que é amplamente reconhecido por sua capacidade de lidar com problemas de classificação não linear, conforme definido a seguir:

$$K(\mathbf{x}_k, \mathbf{x}) = \exp\left(-\frac{\|\mathbf{x}_k - \mathbf{x}\|^2}{2\sigma^2}\right), \quad (6.1)$$

em que \mathbf{x}_k e \mathbf{x} representam os vetores de características de dois exemplos distintos no espaço de alta dimensionalidade. A norma Euclidiana $\|\mathbf{x}_k - \mathbf{x}\|$ calcula a distância entre esses dois vetores. O parâmetro σ controla a amplitude da função do *kernel*, influenciando o grau de suavidade ou sensibilidade do *kernel* à distância entre os vetores. A função exponencial \exp transforma essa distância em uma métrica de similaridade, onde valores próximos de 1 indicam alta similaridade (vetores próximos) e valores próximos de 0 indicam baixa similaridade (vetores distantes).

O *kernel radial basis function* mapeia as características extraídas pela CNN para um espaço de alta dimensionalidade, onde a separação entre as classes se torna mais fácil. Este *kernel* é especialmente adequado para o problema de classificação de células FVs, onde as fronteiras entre as classes não são linearmente separáveis.

Outro parâmetro essencial é o coeficiente de regularização (C), que controla a margem de tolerância da SVM para classificações errôneas. Um valor alto de C pode fazer com que o modelo se ajuste muito bem ao conjunto de treinamento, mas corra o risco de *overfitting*. Por outro lado, um valor muito baixo pode resultar em um modelo que generaliza melhor, mas com uma margem de classificação menos definida. Neste trabalho, o valor de C foi ajustado para equilibrar a precisão do modelo com sua capacidade de generalização, utilizando técnicas de validação cruzada.

A configuração do parâmetro *gamma* (γ) é também fundamental, uma vez que este controla a influência de um único exemplo de treinamento. Um valor de γ muito alto pode resultar em um modelo excessivamente complexo, com uma superfície de decisão muito sensível às variações dos dados de entrada. Por isso, o valor de γ foi ajustado para garantir que o modelo possa capturar as complexidades dos dados sem se tornar excessivamente sensível ao ruído.

Os parâmetros C e γ da SVM foram definidos por meio de uma busca em grade através da classe *GridSearchCV* da biblioteca *Scikit-Learn* (WALT *et al.*, 2014), que exploram diferentes combinações de valores de C e γ identificando a configuração que maximiza a acurácia da classificação. Esse processo de otimização é essencial, pois permite a exploração de uma ampla gama de configurações de parâmetros, resultando em um modelo otimizado que é bem adaptado às particularidades do conjunto de dados de células FVs.

7 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados os resultados obtidos em cada experimento deste trabalho. Ademais, serão realizadas comparações do modelo proposto com algoritmos elementares de classificação e outras topologias de CNNs, assim como o impacto dos resultados obtidos ao se utilizar técnicas de aumento de dados para gerar novas amostras de imagens com base nas originais. Por fim, será verificada a eficácia do modelo HCNN com base nos resultados disponíveis no estado da arte.

7.1 Experimentos de Classificação com Algoritmos Elementares

Inicialmente foram realizados experimentos de classificação de defeitos através dos algoritmos SVM, NB, kNN e RF sem aumento de dados e sem ajuste fino com o intuito de utilizar diferentes abordagens e capacidades de modelagem. Ademais, esses algoritmos são amplamente utilizados na literatura, possuindo uma facilidade em suas implementações e baixo custo computacional. Os modelos foram treinados com a base de dados original pré-processada com a técnica CLAHE.

Os modelos foram implementados utilizando a biblioteca *Scikit-Image* (WALT *et al.*, 2014) e seus hiperparâmetros foram definidos por meio de uma busca em grade através da classe *GridSearchCV* que oferece valores padrões para cada modelo com base em problemas pré-definidos na literatura. Para cada algoritmo, verificou-se as métricas de acurácia, precisão, sensibilidade e *F1-score* com validação cruzada (*k-fold*), adotando-se um número de 5 *folds*. Os resultados obtidos neste experimento são apresentados a seguir.

A Tabela 5 apresenta os resultados em termos de acurácia com seu respectivo desvio padrão como resultado da validação cruzada. Em negrito, destacam-se os melhores resultados para cada modelo. Verifica-se que para este experimento o algoritmo RF se destacou, obtendo uma acurácia média de 89,04%, seguido da SVM com 85,71%. As métricas de sensibilidade, precisão e *F-score* estão dispostas nas Tabelas 6, 7 e 8, respectivamente.

Na Tabela 6, são apresentadas as medidas de sensibilidade dos quatro classificadores. A métrica obtida pelos modelos estima a probabilidade das células com defeito e funcionais serem classificadas de acordo com a sua respectiva classe. Isto quer dizer, por exemplo, que para um conjunto de cem células FVs com defeito, com $S_s = 93\%$, mostra que o classificador realizou a predição corretamente de 93 das 100 imagens. Neste caso, verifica-se mais uma vez que o

Tabela 5 – Resultado da acurácia dos classificadores elementares em cada *fold*.

| <i>Fold</i> | RF | SVM | NB | KNN |
|--------------|---------------------|---------------------|---------------------|---------------------|
| 1 | 0,8913±0,05 | 0,8745 ±0,05 | 0,8257±0,05 | 0,8179±0,06 |
| 2 | 0,8952±0,05 | 0,8528±0,04 | 0,8164±0,07 | 0,8412 ±0,08 |
| 3 | 0,8934±0,04 | 0,8561±0,03 | 0,8229±0,05 | 0,8223±0,07 |
| 4 | 0,8720±0,05 | 0,8447±0,04 | 0,8523 ±0,04 | 0,8341±0,06 |
| 5 | 0,9001 ±0,03 | 0,8574±0,04 | 0,8418±0,05 | 0,8356±0,04 |
| Média | 0,8904±0,01 | 0,8571±0,01 | 0,8318±0,01 | 0,8302±0,01 |

Fonte: Elaborado pelo Autor (2024).

Tabela 6 – Resultado da sensibilidade dos classificadores elementares em cada *fold*.

| <i>Fold</i> | RF | SVM | NB | KNN |
|--------------|---------------------|---------------------|---------------------|---------------------|
| 1 | 0,8524±0,07 | 0,8312±0,05 | 0,8635±0,07 | 0,8604 ±0,07 |
| 2 | 0,8567±0,09 | 0,8541 ±0,08 | 0,8508±0,07 | 0,8445±0,05 |
| 3 | 0,8813±0,06 | 0,8325±0,07 | 0,8446±0,07 | 0,8568±0,07 |
| 4 | 0,8745±0,04 | 0,8412±0,08 | 0,8648 ±0,07 | 0,8519±0,07 |
| 5 | 0,9017 ±0,05 | 0,8546±0,05 | 0,8419±0,02 | 0,8475±0,06 |
| Média | 0,8733±0,02 | 0,8427±0,01 | 0,8531±0,01 | 0,8522±0,01 |

Fonte: Elaborado pelo Autor (2024).

classificador RF obteve o melhor resultado, seguido dos classificadores NB e kNN. O algoritmo SVM sofreu uma pequena redução de sua métrica quando comparado com os resultados das Tabelas 6 e 7.

A Tabela 7 apresenta as medidas da métrica de precisão. Observa-se que a probabilidade de a predição positiva estar correta, ou seja, dos modelos classificarem corretamente as células como funcionais foi bem avaliada por todos os classificadores, com destaque para o NB com uma precisão média de 93,34% e desvio padrão médio de $\pm 1\%$, seguido do RF com 93,02% e desvio padrão médio de $\pm 1\%$. Por fim, a SVM obteve a menor precisão média, mas ainda assim considerada competitiva com 89,04%. Os resultados da Tabela 7 demonstram que tanto as células consideradas defeituosas quanto as funcionais foram classificadas de forma eficaz.

Os resultados apresentados na Tabela 8 representam a combinação das métricas de precisão e sensibilidade, de forma balanceada. Neste experimento o classificador RF se destacou dentre os outros, tendo como melhor resultado um *F-score* médio de 88,46%, seguido da SVM com 86,50%, kNN com 82,56% e NB com 81,01%.

Por fim, o classificador RF se consolidou como o melhor dentre os quatro utilizados chegando a uma acurácia média de 89,04%. Um dos motivos para que o RF sejam tão preciso

Tabela 7 – Resultado da precisão dos classificadores elementares em cada *fold*.

| <i>Fold</i> | RF | SVM | NB | KNN |
|--------------|--------------------|--------------------|--------------------|--------------------|
| 1 | 0,9223±0,06 | 0,9234±0,08 | 0,9147±0,04 | 0,9311±0,05 |
| 2 | 0,9341±0,06 | 0,8928±0,04 | 0,9217±0,07 | 0,9423±0,05 |
| 3 | 0,9308±0,03 | 0,8845±0,07 | 0,9422±0,04 | 0,9156±0,06 |
| 4 | 0,9236±0,04 | 0,8857±0,06 | 0,9439±0,06 | 0,9248±0,04 |
| 5 | 0,9402±0,05 | 0,8654±0,05 | 0,9443±0,04 | 0,9275±0,05 |
| Média | 0,9302±0,01 | 0,8904±0,02 | 0,9334±0,01 | 0,9283±0,01 |

Fonte: Elaborado pelo Autor (2024).

em classificações binárias é porque o mesmo combina centenas ou milhares de DTs, treina cada uma em um conjunto ligeiramente diferente de observações, dividindo nós em cada árvore considerando um número limitado de atributos. As previsões finais do RF são feitas pela média das previsões de cada árvore individual.

Tabela 8 – Resultado dos classificadores elementares por meio da métrica *F-score*.

| <i>Fold</i> | RF | SVM | NB | KNN |
|--------------|--------------------|--------------------|--------------------|--------------------|
| 1 | 0,8604±0,05 | 0,8819±0,06 | 0,8358±0,05 | 0,8312±0,07 |
| 2 | 0,8843±0,04 | 0,8627±0,05 | 0,8024±0,07 | 0,8165±0,04 |
| 3 | 0,9025±0,05 | 0,8549±0,05 | 0,8021±0,07 | 0,8213±0,05 |
| 4 | 0,8848±0,04 | 0,8641±0,05 | 0,8027±0,07 | 0,8345±0,05 |
| 5 | 0,8912±0,05 | 0,8613±0,04 | 0,8075±0,06 | 0,8246±0,06 |
| Média | 0,8846±0,01 | 0,8650±0,01 | 0,8101±0,01 | 0,8256±0,01 |

Fonte: Elaborado pelo Autor (2024).

7.2 Experimentos de Classificação com os Modelos ResNet50, VGG16 e InceptionV3

Neste experimento, verificou-se como os modelos ResNet50, VGG16 e *InceptionV3* pré-treinados com a base ImageNet se comportaram no processo de classificação de defeitos nas células FVs de Si-m e Si-p sem o AFG para otimização dos hiperparâmetros. Os referidos modelos foram implementados tendo em vista serem amplamente utilizados nos trabalhos referenciados no estado da arte. Os hiperparâmetros de cada rede, assim como a quantidade de parâmetros treináveis estão disponíveis na Tabela 9. O processo de classificação ocorreu utilizando-se a base de dados aumentada, contendo 13.120 imagens de células FVs já pré-processamento com a técnica CLAHE, além de terem sido realizados experimentos de validação cruzada. Os modelos foram treinados em 130 épocas e *batch size* igual a 30, tendo em vista não haver melhora em termos de acurácia com um número de épocas maior.

Tabela 9 – Hiperparâmetros das Redes ResNet50, VGG16 e *InceptionV3*.

| Hiperparâmetro | ResNet50 | VGG16 | <i>InceptionV3</i> |
|-------------------------------------|---|---|---|
| Quantidade de Camadas | 50 | 16 | 48 |
| Função de Ativação | ReLU | ReLU | ReLU |
| Quantidade de Parâmetros Treináveis | 25,6 milhões | 138,4 milhões | 23,9 milhões |
| Tamanho do <i>Input</i> | 224×224 | 224×224 | 299×299 |
| Estrutura Principal | Blocos Residuais | Convoluções Empilhadas | Módulos <i>Inception</i> |
| Camada Final | <i>Fully Connected</i> + <i>Softmax</i> | <i>Fully Connected</i> + <i>Softmax</i> | <i>Fully Connected</i> + <i>Softmax</i> |

Fonte: Elaborado pelo Autor (2024).

A Tabela 10 apresenta a acurácia de cada modelo de CNN em seu respectivo *fold*. Através dos resultados obtidos, nota-se que o modelo *InceptionV3* obteve a melhor acurácia média com 93,26%. O modelo ResNet50, por sua vez, apresentou a melhor acurácia no *fold 3* com 94,34%, enquanto o VGG16 destacou-se nos *folds 2* e *4* com 94,31% e 94,42%, respectivamente. Esses resultados evidenciam que, apesar de todos os modelos terem apresentado desempenhos elevados, há variabilidade em suas performances dependendo do *fold* analisado.

Uma vantagem clara do *InceptionV3* é sua arquitetura, que combina múltiplas convoluções de diferentes tamanhos em paralelo, permitindo a captura de padrões mais complexos e variados nas imagens. Essa capacidade de processamento multiescala pode explicar seu desempenho superior em termos de acurácia. No entanto, essa complexidade também se traduz em uma desvantagem, tendo em vista o alto custo computacional.

O ResNet50, com sua arquitetura baseada em conexões residuais, facilita o treinamento de redes muito profundas ao mitigar o problema do gradiente. Isso permite que o modelo aprenda representações mais robustas das imagens, o que é evidenciado pela sua alta acurácia no *fold 3*. A principal desvantagem do ResNet50, contudo, é que, apesar de suas conexões residuais, ele ainda pode ser suscetível a *overfitting* em conjuntos de dados menores ou menos variados.

O VGG16, com sua arquitetura mais simples e profunda baseada em convoluções sequenciais, é conhecido pela facilidade de implementação e bom desempenho em tarefas de classificação de imagens. A simplicidade do VGG16, no entanto, pode ser uma desvantagem, já que ele não possui mecanismos avançados para capturar a diversidade de padrões que modelos como o *InceptionV3* conseguem.

A variação nos desempenhos entre os *folds* também sugere que os dados possuem características que afetam de maneira diferenciada a eficácia de cada modelo. A técnica de

aumento de dados e pré-processamento com *CLAHE* contribui para melhorar a qualidade das imagens, destacando detalhes relevantes que facilitam a tarefa dos modelos de aprendizado profundo.

Tabela 10 – Resultado da acurácia dos modelos de aprendizado profundo ResNet50, VGG16 e *InceptionV3* em cada *fold* utilizando a base de dados aumentada e com as imagens pré-processadas com a técnica *CLAHE*.

| <i>Fold</i> | ResNet50 | VGG16 | <i>InceptionV3</i> |
|--------------|--------------------|--------------------|--------------------|
| 1 | 0,9112±0,01 | 0,9238±0,03 | 0,9425±0,05 |
| 2 | 0,9223±0,02 | 0,9431±0,04 | 0,9176±0,06 |
| 3 | 0,9434±0,03 | 0,9119±0,05 | 0,9315±0,02 |
| 4 | 0,9357±0,04 | 0,9442±0,01 | 0,9283±0,07 |
| 5 | 0,9216±0,07 | 0,9318±0,06 | 0,9429±0,01 |
| Média | 0,9268±0,03 | 0,9310±0,04 | 0,9326±0,04 |

Fonte: Elaborado pelo Autor (2024).

As métricas de sensibilidade, precisão e *F-score* obtidas por cada modelo são apresentadas nas Tabelas 11, 12 e 13, respectivamente. A Tabela 11 mostra que, em termos de sensibilidade, os modelos apresentam desempenhos muito próximos. O modelo VGG16 obteve uma média mais alta de 93,47%, seguido de perto pelos modelos *InceptionV3* com 92,53% e ResNet50 com 92,05%. Isso indica que todos os modelos são igualmente eficazes em identificar corretamente as células FVs não-funcionais, com VGG16 ligeiramente à frente.

Tabela 11 – Resultado da sensibilidade dos modelos de aprendizado profundo ResNet50, VGG16 e *InceptionV3* em cada *fold*.

| <i>Fold</i> | ResNet50 | VGG16 | <i>InceptionV3</i> |
|--------------|--------------------|--------------------|--------------------|
| 1 | 0,9114±0,03 | 0,9226±0,04 | 0,9342±0,05 |
| 2 | 0,9231±0,04 | 0,9425±0,02 | 0,9147±0,06 |
| 3 | 0,9329±0,02 | 0,9118±0,05 | 0,9214±0,07 |
| 4 | 0,9137±0,01 | 0,9345±0,03 | 0,9421±0,04 |
| 5 | 0,9216±0,05 | 0,9419±0,06 | 0,9143±0,03 |
| Média | 0,9205±0,03 | 0,9347±0,04 | 0,9253±0,05 |

Fonte: Elaborado pelo Autor (2024).

Na Tabela 12, observa-se que a VGG16 também lidera na métrica de precisão com uma média de 93,21%, enquanto ResNet50 e *InceptionV3* apresentaram uma precisão média de 92,21% e 92,57%, respectivamente. A precisão elevada do VGG16 sugere que este modelo é um pouco melhor em minimizar FPs, ou seja, em identificar corretamente as células FVs não-funcionais.

Por fim, a Tabela 13 apresenta os resultados do *F-score*, uma métrica que combina

Tabela 12 – Resultado da precisão dos modelos de aprendizado profundo ResNet50, VGG16 e *InceptionV3* em cada *fold*.

| <i>Fold</i> | ResNet50 | VGG16 | <i>InceptionV3</i> |
|--------------|--------------------|--------------------|---------------------------|
| 1 | 0,9234±0,02 | 0,9431±0,03 | 0,9145±0,04 |
| 2 | 0,9147±0,01 | 0,9216±0,05 | 0,9342±0,02 |
| 3 | 0,9243±0,03 | 0,9125±0,02 | 0,9439±0,06 |
| 4 | 0,9325±0,04 | 0,9217±0,01 | 0,9134±0,07 |
| 5 | 0,9158±0,05 | 0,9428±0,02 | 0,9223±0,03 |
| Média | 0,9221±0,03 | 0,9323±0,03 | 0,9257±0,04 |

Fonte: Elaborado pelo Autor (2024).

a precisão e a sensibilidade. Aqui, os três modelos apresentam um desempenho muito similar, todos com uma média aproximada de 92%, com o VGG16 ligeiramente à frente com 92,65%. Isso reforça a consistência entre os modelos, mas destaca o VGG16 como ligeiramente superior no balanço entre precisão e sensibilidade.

Tabela 13 – Resultado do *F-score* dos modelos de aprendizado profundo ResNet50, VGG16 e *InceptionV3* em cada *fold*.

| <i>Fold</i> | ResNet50 | VGG16 | <i>InceptionV3</i> |
|--------------|--------------------|--------------------|---------------------------|
| 1 | 0,9142±0,02 | 0,9223±0,01 | 0,9345±0,04 |
| 2 | 0,9248±0,03 | 0,9431±0,06 | 0,9176±0,05 |
| 3 | 0,9154±0,04 | 0,9318±0,02 | 0,9425±0,01 |
| 4 | 0,9437±0,05 | 0,9149±0,03 | 0,9214±0,07 |
| 5 | 0,9315±0,01 | 0,9212±0,04 | 0,9153±0,02 |
| Média | 0,9259±0,03 | 0,9265±0,03 | 0,9263±0,04 |

Fonte: Elaborado pelo Autor (2024).

Embora todos os três modelos apresentem desempenhos semelhantes, o VGG16 se encontra ligeiramente à frente nas métricas de sensibilidade e precisão, sugerindo que o mesmo tenha se destacado na tarefa de classificação de células FVs de Si-m e Si-p, especialmente quando a precisão na identificação das células funcionais é crítica. No entanto, a diferença de desempenho é pequena, levando-se à consideração de outros fatores como a complexidade do modelo, o tempo de treinamento e a quantidade de parâmetros treináveis.

Comparando os resultados obtidos por meio dos algoritmos elementares apresentados na Seção 7.1 com os modelos ResNet50, VGG16 e *InceptionV3*, observa-se um aumento significativo nas métricas de acurácia, precisão, sensibilidade e *F1-score* ao utilizar as DNNs. Em termos percentuais, os modelos de aprendizado profundo superam consistentemente os métodos tradicionais em até 5%, com destaque para o *InceptionV3*, que apresentou uma acurácia média de 93,26%, em comparação com a melhor acurácia dos algoritmos elementares, que foi

de 89,04% com o RF. Essa diferença evidencia a superioridade dos modelos de aprendizado profundo na extração de características complexas e na classificação de imagens de células FVs, especialmente em contextos onde a precisão e a generalização são fundamentais.

7.3 Ajuste Fino Genético sem Aumento de Dados

Nessa etapa do trabalho foram realizados experimentos de classificação utilizando o AFG em busca dos hiperparâmetros ótimos da HCNN pré-treinada com a base de imagens ImageNet. Verificou-se inicialmente se o número de amostras de imagens iria fazer alguma diferença no processo de aprendizagem do modelo, logo para este experimento utilizou-se a base de dados original com as 2.674 imagens em EL de células FVs pré-processamento com a técnica CLAHE e a busca dos hiperparâmetros, conforme apresentado na Tabela 4.

A Tabela 14 apresenta os resultados do AFG para os dez melhores indivíduos das topologias ResNet50+SVM e VGG16+SVM. Entre as topologias testadas, a combinação VGG16+SVM com uma camada de 1.024 neurônios, função de ativação *selu*, otimizador *rmsprop* e 50% de *dropout*, obteve os melhores resultados. Este modelo apresentou um índice *Kappa* de 78,23% e uma acurácia de 95,21%. O alto valor de acurácia indica que o modelo conseguiu classificar corretamente a grande maioria das amostras das células funcionais e não-funcionais, enquanto o índice *Kappa* sugere uma boa concordância entre as previsões do modelo e os rótulos verdadeiros. A especificidade de 96,32% e a sensibilidade de 94,47% reforçam a capacidade do modelo de distinguir corretamente entre as classes, minimizando tanto os FPs quanto os FNs.

Já o ResNet50+SVM com 768 neurônios na primeira camada, 512 neurônios na segunda camada, função de ativação *relu*, otimizador *adam* e 50% de *dropout* alcançou uma acurácia de 94,43% e um índice *Kappa* de 74,15%, demonstrando também um desempenho robusto. A especificidade de 96,18% e a precisão de 94,27% indicam que este modelo é altamente eficaz em identificar corretamente as amostras positivas, embora o índice *Kappa* ligeiramente inferior sugira uma leve variação nas previsões comparadas aos rótulos verdadeiros.

A comparação entre a quantidade de hiperparâmetros treináveis dos melhores modelos de cada topologia mostra que a VGG16 tende a ter menos hiperparâmetros treináveis devido à sua arquitetura mais simples em comparação à ResNet50, que é mais profunda e complexa. A configuração da VGG16 com uma camada de 1.024 neurônios implica em um menor número de parâmetros a serem ajustados, o que pode explicar a sua ligeiramente melhor performance em

Tabela 14 – Resultados do ajuste fino genético para os dez melhores indivíduos das topologias ResNet50+SVM e VGG16+SVM, suas características e métricas obtidas utilizando a base de dados contendo 2.624 amostras.

| Topologia do Modelo | Cam. | N1. | N2. | Atv. | Otim. | Aband. κ | A_{cc} | S_s | E | P | $F - score$ | |
|----------------------------|-------------|-------------|------------|-------------|----------------|-----------------------------------|---------------|---------------|---------------|---------------|---------------|---------------|
| VGG16+SVM | 1 | 1024 | - | selu | rmsprop | 50% | 0,7823 | 0,9521 | 0,9447 | 0,9632 | 0,9345 | 0,9217 |
| VGG16+SVM | 1 | 512 | - | elu | adam | 40% | 0,7912 | 0,9448 | 0,9221 | 0,9523 | 0,9115 | 0,9324 |
| VGG16+SVM | 2 | 512 | 768 | tanh | adadelta | 60% | 0,7814 | 0,9356 | 0,9147 | 0,9433 | 0,9019 | 0,9421 |
| VGG16+SVM | 2 | 1024 | 256 | exp. | adam | 30% | 0,7731 | 0,9245 | 0,9362 | 0,9328 | 0,9254 | 0,9134 |
| VGG16+SVM | 2 | 512 | 1024 | tanh | rmsprop | 50% | 0,7654 | 0,9167 | 0,9034 | 0,9431 | 0,8912 | 0,9028 |
| VGG16+SVM | 1 | 768 | - | relu | sgd | 40% | 0,7539 | 0,9125 | 0,8937 | 0,9221 | 0,9128 | 0,9316 |
| VGG16+SVM | 2 | 256 | 512 | tanh | adam | 60% | 0,7431 | 0,9253 | 0,9149 | 0,9234 | 0,9021 | 0,9428 |
| ResNet50+SVM | 2 | 768 | 512 | relu | adam | 50% | 0,7415 | 0,9443 | 0,9376 | 0,9618 | 0,9427 | 0,9114 |
| ResNet50+SVM | 2 | 256 | 768 | selu | sgd | 30% | 0,7843 | 0,9417 | 0,9264 | 0,9514 | 0,9312 | 0,9236 |
| ResNet50+SVM | 1 | 512 | - | elu | adadelta | 40% | 0,7651 | 0,9318 | 0,9442 | 0,9421 | 0,9145 | 0,9317 |

Fonte: Elaborado pelo Autor (2024).

termos de índice *Kappa* e acurácia. Em contrapartida, a ResNet50, apesar de ter mais parâmetros, consegue alcançar uma acurácia comparável, sugerindo que sua arquitetura mais complexa também é capaz de capturar de forma eficaz as características dos dados. Para este experimento, os resultados indicam que tanto VGG16+SVM quanto ResNet50+SVM em conjunto com o AFG demonstraram ser abordagens eficazes para a tarefa de classificação, com VGG16+SVM ligeiramente superior em termos de robustez de predição.

A comparação entre os resultados obtidos pelos algoritmos elementares da Seção 7.1 e os modelos ResNet50, VGG16, *InceptionV3*, apresentados na Seção 7.2 com os dessa Seção, revela um progresso considerável nas métricas de desempenho. Os algoritmos elementares, como o RF, alcançaram uma acurácia máxima de 89,04%, enquanto os modelos de aprendizado profundo como o *InceptionV3* e o VGG16 elevaram essa acurácia para até 93,26%, um aumento de aproximadamente 5%. Com o AFG, os modelos VGG16+SVM e ResNet50+SVM atingiram acurácias ainda mais altas, de 95,21% e 94,43%, respectivamente, representando um aumento percentual de cerca de 7% em relação aos métodos elementares e de 2% em relação aos modelos de aprendizado profundo. Ademais, o VGG16+SVM obteve a melhor performance geral, com uma sensibilidade de 94,47% e uma precisão de 93,45%, reforçando a eficácia do AFG em maximizar o desempenho dos modelos, especialmente na classificação de imagens complexas como células FVs não-funcionais.

7.4 Ajuste Fino Genético com Aumento de Dados

Nessa última etapa do trabalho foram realizados experimentos de classificação utilizando o AFG na busca dos hiperparâmetros ótimos da HCNN também pré-treinada com ImageNet em conjunto com a base de dados aumentada e pré-processamento com a técnica CLAHE. A Tabela 15 apresenta os resultados do AFG para os dez melhores indivíduos por CNN+SVM, utilizando o conjunto de dados contendo 13.120 amostras.

Tabela 15 – Resultados do ajuste fino genético para os dez melhores indivíduos das topologias ResNet50+SVM e VGG16+SVM, suas características e métricas obtidas utilizando a base de dados aumentada contendo 13.120 amostras.

| Topologia da CNN | Cam. | N1. | N2. | Atv. | Otim. | Aband. | κ | A_{cc} | S_s | E | P | F – score |
|---------------------|----------|-------------|------|-------------|-----------------|------------|---------------|---------------|---------------|---------------|---------------|---------------|
| VGG16+SVM | 1 | 768 | - | relu | adam | 50% | 0,7523 | 0,9534 | 0,9321 | 0,9538 | 0,9337 | 0,9441 |
| VGG16+SVM | 2 | 1024 | 768 | tanh | sgd | 40% | 0,7235 | 0,9447 | 0,9243 | 0,9449 | 0,9214 | 0,9318 |
| VGG16+SVM | 1 | 512 | - | selu | rmsprop | 60% | 0,7148 | 0,9312 | 0,9128 | 0,9325 | 0,9135 | 0,9246 |
| VGG16+SVM | 1 | 1024 | - | relu | adam | 30% | 0,7452 | 0,9423 | 0,9249 | 0,9432 | 0,9256 | 0,9334 |
| VGG16+SVM | 1 | 768 | - | elu | adadelta | 50% | 0,8017 | 0,9967 | 0,9712 | 0,9841 | 0,9742 | 0,9756 |
| ResNet50+SVM | 2 | 512 | 1024 | exp. | adam | 60% | 0,7029 | 0,9328 | 0,9127 | 0,9215 | 0,9138 | 0,9241 |
| ResNet50+SVM | 2 | 512 | 512 | tanh | rmsprop | 50% | 0,6941 | 0,9314 | 0,9146 | 0,9223 | 0,9131 | 0,9248 |
| ResNet50+SVM | 1 | 1024 | - | relu | adam | 40% | 0,8526 | 0,9817 | 0,9645 | 0,9734 | 0,9623 | 0,9748 |
| ResNet50+SVM | 2 | 512 | 768 | selu | sgd | 30% | 0,7324 | 0,9418 | 0,9234 | 0,9341 | 0,9216 | 0,9345 |
| ResNet50+SVM | 2 | 768 | 512 | tanh | rmsprop | 50% | 0,7543 | 0,9523 | 0,9324 | 0,9431 | 0,9342 | 0,9436 |

Fonte: Elaborado pelo Autor (2024).

Os melhores resultados foram obtidos com a topologia VGG16+SVM, utilizando uma camada de 768 neurônios, função de ativação *elu*, otimizador *adadelta* e 50% de *dropout*. Este modelo alcançou um índice *Kappa* de 80,17% e uma acurácia de 99,67%. Esses valores indicam uma concordância entre as previsões do modelo e os rótulos VP e VN, além de uma alta capacidade de classificação. A especificidade de 98,41% e a sensibilidade de 97,12% reforçam a eficácia do modelo em distinguir corretamente entre as classes, minimizando tanto os FPs quanto os FNs.

Já a topologia ResNet50+SVM, com uma camada de 1.024 neurônios, função de ativação *relu*, otimizador *adam* e 40% de *dropout* alcançou uma acurácia de 98,17% e um índice *Kappa* de 85,26%, demonstrando um ótimo desempenho. A especificidade de 97,34% e a precisão de 96,23% indicam que este modelo é altamente eficaz em identificar corretamente as amostras positivas. Comparado ao melhor resultado da VGG16+SVM, o ResNet50+SVM

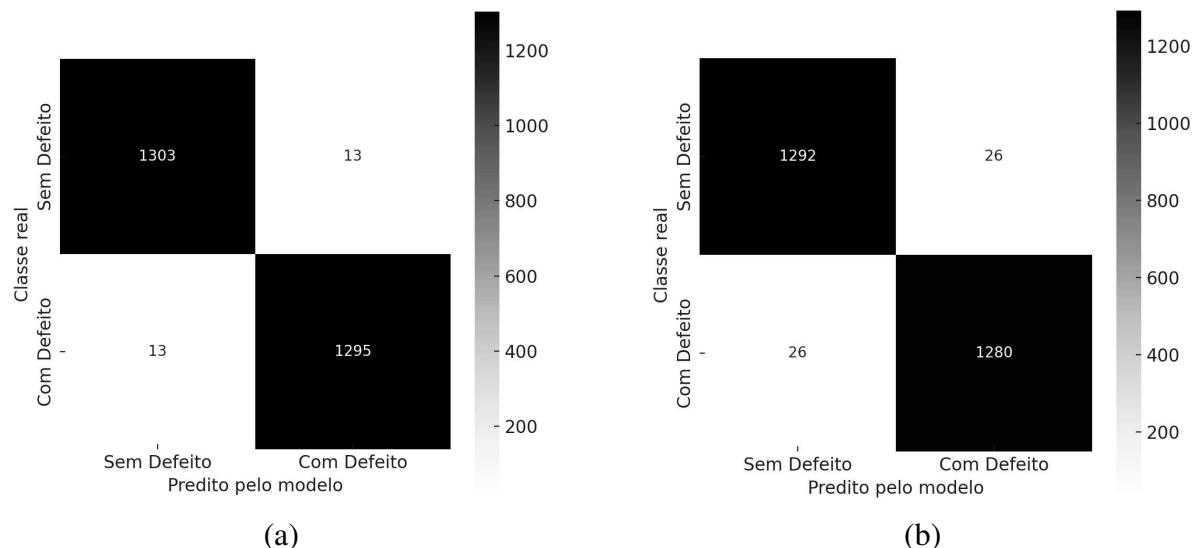
apresentou uma robustez ligeiramente inferior, mas ainda assim competitiva.

Comparando os resultados obtidos com os apresentados na Tabela 14, observa-se uma melhoria significativa nas métricas de desempenho, especialmente na acurácia e no índice *Kappa*. A técnica de aumento de dados contribuiu para essa melhoria, proporcionando uma base mais ampla e variada para o treinamento, o que resultou em modelos mais robustos e generalizáveis.

A VGG16+SVM, com sua arquitetura mais simples, possui menos hiperparâmetros treináveis em comparação à ResNet50, que é mais profunda e complexa. Essa diferença pode explicar a ligeira melhor performance da VGG16+SVM em termos de acurácia e índice *Kappa*. Contudo, a complexidade adicional da ResNet50+SVM permite capturar nuances mais detalhadas dos dados, como refletido na alta especificidade e precisão.

Neste último experimento a topologia HCNN VGG16+SVM se destacou como o melhor modelo em termos de acurácia. O uso da técnica de aumento de dados foi crucial para alcançar esses resultados superiores, evidenciando sua importância na construção de modelos de ML robustos e confiáveis. A Figura 12(a) e 12(b) apresentam as matrizes de confusão dos melhores resultados em termos de acurácia obtidos por cada modelo apresentado na Tabela 15.

Figura 12 – (a) Matriz de confusão do melhor resultado obtido pela HCNN VGG16+SVM. (b) Matriz de confusão do melhor resultado obtido pela HCNN ResNet50+SVM.



Fonte: Elaborado pelo Autor (2024).

A matriz de confusão da topologia VGG16+SVM apresenta 1.303 VNs e 1.295 VPs, com apenas 13 FPs e FNs. Esses resultados refletem a acurácia de 99,67% alcançada pelo modelo. A especificidade e a sensibilidade são altas, indicando que o modelo é eficaz tanto em

identificar corretamente as amostras funcionais quanto em detectar as amostras não-funcionais. A baixa quantidade de FPs e FNs evidencia a capacidade do modelo em minimizar erros de classificação, proporcionando uma performance competitiva.

Já a matriz do modelo ResNet50+SVM apresenta 1.292 VNs e 1.280 VPs, com 26 FPs e 26 FNs. Esses resultados são consistentes com a acurácia de 98,17% do modelo. Embora o ResNet50+SVM também apresente alta especificidade e sensibilidade, a presença de um maior número de FPs e FNs em comparação ao VGG16+SVM sugere que este modelo é ligeiramente menos eficaz em minimizar erros de classificação. No entanto, ainda demonstra uma performance robusta e eficiente.

A Tabela 16 apresenta a comparação entre os algoritmos elementares da Seção 7.1, os modelos de aprendizado profundo da Seção 7.2, e o modelo de HCNN com ajuste fino sem aumento de dados da Seção 7.3, com os resultados dessa Seção, evidenciando uma evolução clara nas métricas de desempenho à medida que técnicas mais avançadas são aplicadas. Os algoritmos elementares, como o RF, alcançaram uma acurácia média de 89,04%, enquanto os modelos de aprendizado profundo elevaram essa acurácia para até 93,26%, representando um aumento de aproximadamente 5%. Com o AFG sem aumento de dados, as acurácias subiram para 95,21%, um incremento adicional de 2%. Por fim, a HCNN com AFG e aumento de dados elevou ainda mais o desempenho, atingindo uma acurácia de 99,67% com a topologia VGG16+SVM, um aumento total de aproximadamente 12% em relação aos algoritmos elementares. Esse progresso contínuo demonstra a eficácia de estratégias como o AFG e o aumento de dados, que juntos maximizam a robustez e a generalização dos modelos, especialmente na tarefa complexa de classificação de defeitos em células FVs.

Tabela 16 – Melhores resultados de acurácia por experimento e aumento percentual em relação ao experimento anterior.

| Experimento | Melhor Acurácia (%) | Aumento Percentual (%) |
|-------------------------------|----------------------------|-------------------------------|
| Algoritmos Elementares | 89,04 | - |
| Modelos de AP | 93,26 | 4,75 |
| HCNN + AFG sem AD | 95,21 | 2,09 |
| HCNN + AFG com AD | 99,67 | 4,69 |

Fonte: Elaborado pelo Autor (2024).

7.5 Comparação com o Estado da Arte

A Tabela 17 apresenta uma comparação detalhada entre os resultados obtidos neste trabalho e os resultados de estudos anteriores no estado da arte focados na detecção de defeitos em células de módulos FVs de Si-m e Si-p em imagens EL. Neste trabalho, destaca-se a HCNN, que combina características de várias arquiteturas de redes profundas, otimização de hiperparâmetros por meio de algoritmos genéticos, e classificação final utilizando uma SVM.

Em comparação com estudos anteriores, este trabalho se destaca pelo uso de técnicas avançadas de ML e por alcançar resultados superiores em quase todas as métricas avaliadas. Em particular, a acurácia de 99,67% é a mais alta entre os estudos comparados, indicando a eficácia da abordagem híbrida. A sensibilidade, precisão, especificidade e *F-score* obtidos neste trabalho também são superiores ou comparáveis aos melhores resultados relatados na literatura. Ademais, a proposta apresentada neste trabalho é a única que apresenta a métrica κ , com um valor significativo de 80,17%, e o único trabalho que realizou a implementação de sistemas genéticos evolutivos para encontrar os melhores hiperparâmetros dos modelos ResNet50 e VGG16 o que reforça a consistência e a confiabilidade dos resultados obtidos.

Os resultados indicam que a combinação de uma HCNN com otimização de hiperparâmetros é uma abordagem promissora para a detecção de defeitos em células FVs, superando as metodologias tradicionais em termos de desempenho e robustez.

7.6 Resultados Visuais das Classificações

A classificação de defeitos em células FVs usando imagens em EL é complexa devido à necessidade de identificar padrões sutis e variados que indicam diferentes tipos de defeitos. A variabilidade nas imagens, causada por diferenças de iluminação, ângulo de captura e qualidade das células, aumenta a dificuldade. Ademais, a expertise necessária para distinguir entre defeitos semelhantes e entender suas implicações no desempenho da célula exige conhecimento especializado. A subjetividade humana e a fadiga visual também podem influenciar a precisão da classificação. A análise precisa requer tempo e atenção aos detalhes, tornando o processo demorado e suscetível a erros. Diante disso, o auxílio de algoritmos de aprendizado profundo podem facilitar o processo de classificação.

A Figura 13 apresenta um conjunto de imagens de células FVs, acompanhadas de suas respectivas classes preditas e reais. Cada imagem está categorizada em duas classes: 0

Tabela 17 – Resultados do estado da arte para detecção de defeitos em células de módulos fotovoltaicos em comparação com os melhores resultados do trabalho proposto.


| Trabalho | Célula FV | Base de dados | AFG | κ | A_{cc} | S_s | P | E | $F - Score$ |
|--------------------------------|-------------|---|-----|---------------|-----------------|---------------|---------------|---------------|---------------|
| Et-taleby <i>et al.</i> (2022) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) e (KARIMI <i>et al.</i> , 2019) | Não | - | 0,9949 e 0,9946 | - | - | - | - |
| Fan <i>et al.</i> (2022) | Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,9911 | 0,9884 | 0,9697 | - | 0,9790 |
| Tang <i>et al.</i> (2022) | Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,9300 | - | - | - | - |
| Demirci <i>et al.</i> (2021) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,9452 | 0,9736 | 0,9479 | - | 0,9606 |
| Acharya <i>et al.</i> (2021) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | - | 0,7375 | 0,7475 | - | 0,7375 |
| Tang <i>et al.</i> (2020) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,8300 | - | - | - | - |
| Mathias <i>et al.</i> (2020) | Si-p | Não referenciado | Não | - | 0,9368 | 1,0000 | - | 0,8733 | - |
| Deitsch <i>et al.</i> (2019) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,8842 | - | - | - | - |
| Akram <i>et al.</i> (2019) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,9302 | - | - | - | - |
| Karimi <i>et al.</i> (2018) | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Não | - | 0,9895 | - | - | - | - |
| Proposta do trabalho | Si-m e Si-p | (BUERHOP-LUTZ <i>et al.</i> , 2018) | Sim | 0,8017 | 0,9967 | 0,9712 | 0,9841 | 0,9742 | 0,9756 |

Fonte: Elaborado pelo Autor (2024).

(funcional) e 1 (não-funcional). A linha superior exhibe exemplos de células classificadas como funcionais, enquanto a linha inferior mostra células não-funcionais com defeitos identificados. Em cada imagem de célula FV não-funcional, áreas específicas onde os defeitos são visíveis estão destacadas com retângulos vermelhos. A precisão das predições é evidenciada pela correspondência entre as classes preditas e as reais, indicando um desempenho satisfatório do modelo de classificação empregado. Ademais, observa-se que o modelo VGG+SVM adquiriu

uma boa capacidade de generalização, tendo em vista que as imagens apresentadas na Figura 13 apresentam células FVs de Si-p com os *busbars* na horizontal e vertical.

Figura 13 – Exemplos de classificações realizadas pelo modelo VGG16+SVM com aumento de dados, onde a classe 0.0 representa as imagens de células FVs funcionais e a classe 1.0 representa as imagens de células FVs não-funcionais.



Fonte: Elaborado pelo Autor (2024).

7.7 Desafios e Limitações

Apesar dos resultados apresentados, alguns desafios foram superados. Primeiramente, a disponibilidade limitada de dados de alta qualidade pode impactar significativamente a performance dos modelos de aprendizado profundo, uma vez que a eficácia desses modelos depende fortemente da quantidade e variedade dos dados de treinamento. A técnica de aumento de dados utilizada mitiga, mas não elimina completamente esse problema.

Outro desafio relevante foi o custo computacional associado ao treinamento das CNNs complexas como ResNet50, VGG16 e *InceptionV3*. A necessidade de recursos computacionais avançados limita a replicabilidade do estudo em ambientes com infraestrutura menos robusta. Adicionalmente, a complexidade dos modelos pode levar a problemas de sobreajuste, especialmente quando o conjunto de dados não é suficientemente diversificado, requerendo técnicas de regularização e validação cuidadosas. Diante disso, o ajuste fino dos hiperparâmetros se fez de grande utilidade para reduzir o custo computacional envolvido. A implementação e

ajuste fino de hiperparâmetros por meio de algoritmos genéticos também introduzem desafios. Embora eficaz, este método pode ser computacionalmente intensivo e demorado, e os resultados obtidos dependem da configuração inicial dos parâmetros do algoritmo genético.

Por fim, a generalização dos modelos para diferentes tipos de defeitos em células FVs e para outros contextos industriais permanece uma questão de ampla investigação, fortalecendo a necessidade contínua de pesquisa e desenvolvimento para melhorar a robustez e aplicabilidade dos modelos de aprendizado profundo em ambientes industriais.

8 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho propôs a aplicação de algoritmos elementares e modelos de aprendizado profundo para a classificação de defeitos em células FVs de Si-m e Si-p utilizando técnicas de ML. A metodologia combinou CNNs para a extração de características das imagens com SVM para a classificação binária, além de otimização de hiperparâmetros por AFG.

Os resultados demonstraram um aumento progressivo na acurácia conforme técnicas mais avançadas foram incorporadas. Os algoritmos elementares, como RF, alcançaram uma acurácia média de 89,04%. A introdução de modelos de aprendizado profundo, como VGG16 e *InceptionV3*, elevou a acurácia média para 93,26%, representando um aumento de 4,75%. O modelo de HCNN com AFG, sem aumento de dados e pré-treinada com a ImageNet, aprimorou ainda mais a acurácia para 95,21%, um ganho adicional de 2,09%. Finalmente o modelo de HCNN VGG16+SVM, após otimização com AFG, aumento de dados e pré-treinada com ImageNet, destacou-se com uma acurácia de 99,67% e um índice *Kappa* de 80,17%, representando um aumento de 4,69% em relação aos modelos de aprendizado profundo. Esses resultados evidenciam a contribuição incremental de cada técnica na melhoria da classificação de defeitos em células FVs, validando a eficácia das abordagens propostas.

A técnica de aumento de dados foi crucial para aprimorar a generalização dos modelos, enquanto a CLAHE no pré-processamento das imagens contribuiu significativamente para o desempenho dos modelos, destacando características essenciais. O AFG mostrou-se uma estratégia eficiente na otimização dos hiperparâmetros, permitindo encontrar configurações ótimas para cada topologia de CNN.

Para futuros trabalhos, recomenda-se ampliar a base de dados, incorporando mais imagens de células FVs com diferentes defeitos e variabilidades, a fim de aumentar a robustez e a representatividade dos dados. Ademais, explorar outras arquiteturas de CNNs, como *EfficientNet*, *DenseNet* e *MobileNet*, pode oferecer um equilíbrio entre desempenho e custo computacional. A integração de sistemas de detecção automática em linhas de produção de células FVs pode melhorar a qualidade e a eficiência dos processos de fabricação. Estudos de impacto econômico também são recomendados para avaliar os benefícios de implementar sistemas de detecção automática de defeitos, considerando redução de custos, aumento da eficiência e melhoria da qualidade dos produtos. Essas direções futuras têm o potencial de expandir as capacidades da metodologia proposta, promovendo avanços na detecção de defeitos em células FVs e na eficiência da produção de energia solar.

REFERÊNCIAS

- ACHARYA, A. K.; SAHU, P. K.; JENA, S. R. Deep neural network based approach for detection of defective solar cell. **Materials Today: Proceedings**, v. 39, p. 2009–2014, 2021. ISSN 2214-7853. 3rd International Conference on Solar Energy Photovoltaics. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785320367365>>.
- AKRAM, M. W.; LI, G.; JIN, Y.; CHEN, X.; ZHU, C.; ZHAO, X.; KHALIQ, A.; FAHEEM, M.; AHMAD, A. Cnn based automatic detection of photovoltaic cell defects in electroluminescence images. **Energy**, v. 189, p. 116319, 2019. ISSN 0360-5442.
- AKRAM, M. W.; LI, G.; JIN, Y.; CHEN, X.; ZHU, C.; AHMAD, A. Automatic detection of photovoltaic module defects in infrared images with isolated and develop-model transfer deep learning. **Solar Energy**, v. 198, p. 175–186, 2020. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X20300621>>.
- ALEXANDRE, J. B.; Fernando, H. S.; Ivan, J. G. Uma revisão sobre as tecnologias fotovoltaicas atuais. n. 9, p. 1–9, 2018.
- ALZUBAIDI, L.; ZHANG, J.; HUMAIDI, A. J.; AL-DUJAILI, A.; DUAN, Y.; AL-SHAMMA, O.; SANTAMARÍA, J.; FADHEL, M. A.; AL-AMIDIE, M.; FARHAN, L. Review of deep learning: concepts, cnn architectures, challenges, applications, future directions. **Journal of Big Data**, v. 8, n. 1, p. 53, 2021. ISSN 2196-1115. Disponível em: <<https://doi.org/10.1186/s40537-021-00444-8>>.
- ANAYA-ISAZA, A.; MERA-JIMÉNEZ, L.; ZEQUERA-DIAZ, M. An overview of deep learning in medical imaging. **Informatics in Medicine Unlocked**, v. 26, p. 100723, 2021. ISSN 2352-9148.
- BALASUBRAMANI, G.; THANGAVELU, V.; CHINNUSAMY, M.; SUBRAMANIAM, U.; PADMANABAN, S.; MIHET-POPA, L. Infrared thermography based defects testing of solar photovoltaic panel with fuzzy rule-based evaluation. **Energies**, MDPI AG, v. 13, n. 6, p. 1343, Mar 2020. ISSN 1996-1073.
- BENTLEY, P. J.; CORNE, D. W. An introduction to creative evolutionary systems. In: BENTLEY, P. J.; CORNE, D. W. (Ed.). **Creative Evolutionary Systems**. San Francisco: Morgan Kaufmann, 2002. p. 1–75. ISBN 978-1-55860-673-9. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9781558606739500355>>.
- BISHOP, C. M. **Pattern Recognition and Machine Learning (Information Science and Statistics)**. Berlin, Heidelberg: Springer-Verlag, 2006. ISBN 0387310738.
- BUERHOP, C.; SCHLEGEL, D.; NIESS, M.; VODERMAYER, C.; WEIBMANN, R.; BRABEC, C. Reliability of ir-imaging of pv-plants under operating conditions. **Solar Energy Materials and Solar Cells**, v. 107, p. 154 – 164, 2015. ISSN 0927-0248.
- BUERHOP-LUTZ, C.; DEITSCH, S.; MAIER, A.; GALLWITZ, F.; BERGER, S.; DOLL, B.; HAUCH, J.; CAMUS, C.; BRABEC, C. J. A benchmark for visual identification of defective solar cells in electroluminescence imagery. In: **European PV Solar Energy Conference and Exhibition (EU PVSEC)**. [S.l.: s.n.], 2018.

BUSLAEV, A.; IGLOVIKOV, V. I.; KHVEDCHENYA, E.; PARINOV, A.; DRUZHININ, M.; KALININ, A. A. Albumentations: Fast and flexible image augmentations. **Information**, v. 11, n. 2, 2020. ISSN 2078-2489. Disponível em: <<https://www.mdpi.com/2078-2489/11/2/125>>.

CHAIBI, Y.; MALVONI, M.; CHOUDER, A.; BOUSSETTA, M.; SALHI, M. Simple and efficient approach to detect and diagnose electrical faults and partial shading in photovoltaic systems. **Energy Conversion and Management**, v. 196, p. 330–343, 2019. ISSN 0196-8904. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0196890419306417>>.

CHAUDHARY, A. S.; CHATURVEDI, D. K. Analyzing defects of solar panels under natural atmospheric conditions with thermal image processing. **International Journal of Image, Graphics and Signal Processing**, v. 10, n. 6, p. 10–21, 2018.

CHLAP; H, M.; N, V.; J, D.; L, H.; A., H. A review of medical image data augmentation techniques for deep learning applications. **J Med Imaging Radiat Oncol**, 2021.

COHEN; KAPPA, W. Nominal scale agreement with provision for scaled disagreement or partial credit. **Psychol Bull**, v. 70, p. 213, out. 1968.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1007/BF00994018>>.

CUBUK, E. D.; ZOPH, B.; MANÉ, D.; VASUDEVAN, V.; LE, Q. V. Autoaugment: Learning augmentation policies from data. **CoRR**, abs/1805.09501, 2018. Disponível em: <<http://arxiv.org/abs/1805.09501>>.

CUBUK, E. D.; ZOPH, B.; SHLENS, J.; LE, Q. V. Randaugment: Practical data augmentation with no separate search. **CoRR**, abs/1909.13719, 2019. Disponível em: <<http://arxiv.org/abs/1909.13719>>.

DEITSCH, S.; BUERHOP-LUTZ, C.; SOVETKIN, E.; STELAND, A.; MAIER, A.; GALLWITZ, F.; RIESS, C. Segmentation of photovoltaic module cells in uncalibrated electroluminescence images. **Machine Vision and Applications**, v. 32, n. 4, p. 84, May 2021. ISSN 1432-1769. Disponível em: <<https://doi.org/10.1007/s00138-021-01191-9>>.

DEITSCH, S.; CHRISTLEIN, V.; BERGER, S.; BUERHOP-LUTZ, C.; MAIER, A.; GALLWITZ, F.; RIESS, C. Automatic classification of defective photovoltaic module cells in electroluminescence images. **Solar Energy**, v. 185, p. 455–468, jun. 2019.

DEMIRCI, M. Y.; BEŞLI, N.; GÜMÜŞÇÜ, A. Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in electroluminescence images. **Expert Systems with Applications**, Elsevier, v. 175, p. 114810, 2021.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: **2009 IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2009. p. 248–255.

DENKER, J.; GARDNER, W. R.; GRAF, H.; HENDERSON, D.; HOWARD, R.; HUBBARD, W.; JACKEL, L.; BAIRD, H.; GUYON, I. Neural network recognizer for hand-written zip code digits. **Conference on Neural Information Processing Systems (NeurIPS)**, p. 323–331, 1988.

EIBEN, A. E.; SMITH, J. E. **Introduction to Evolutionary Computing**. 2nd. ed. [S.l.]: Springer Publishing Company, Incorporated, 2015. ISBN 3662448734.

- EPE. Anuário estatístico de energia elétrica 2023 (ano base 2022). **Empresa de Pesquisa Energética (EPE)**, 2023. Disponível em: <https://dashboard.epe.gov.br/apps/anuario-livro/#Notas_explicativas>.
- ET-TALEBY, A.; CHAIBI, Y.; ALLOUHI, A.; BOUSSETTA, M.; BENSLIMANE, M. A combined convolutional neural network model and support vector machine technique for fault detection and classification based on electroluminescence images of photovoltaic modules. **Sustainable Energy, Grids and Networks**, v. 32, p. 100946, 2022. ISSN 2352-4677. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352467722001916>>.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. de Leon Ferreira de. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. [S.l.]: Rio de Janeiro: LTC, 2011. ISBN 9788521618805.
- FAN, T.; SUN; TAO; XIE; XIANGYING; LIU; HU; NA, Z. Automatic micro-crack detection of polycrystalline solar cells in industrial scene. **IEEE Access**, v. 10, p. 16269–16282, 2022.
- FLEISS, J. L.; COHEN, J. The equivalence of weighted kappa and the intraclass correlation coefficient as measures of reliability. **Educational and Psychological Measurement**, v. 33, n. 3, p. 613–619, 1973.
- FRAZAO, M.; SILVA, J.; LOBATO, K.; SERRA, J. Electroluminescence of silicon solar cells using a consumer grade digital camera. **Measurement**, v. 99, p. 7–12, 2017. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224116307187>>.
- FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, v. 36, n. 4, p. 193–202, 1980. ISSN 1432-0770. Disponível em: <<https://doi.org/10.1007/BF00344251>>.
- GONZALEZ, R. C.; WOODS, R. C. **Processamento Digital de Imagens**. [S.l.]: Pearson Education, 2010.
- GUO, G.; ZHANG, N. A survey on deep learning based face recognition. **Computer Vision and Image Understanding**, v. 189, p. 102805, 2019. ISSN 1077-3142.
- Haralick, R. M.; Shanmugam, K.; Dinstein, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-3, n. 6, p. 610–621, 1973.
- HERRAIZ, H.; MARUGÁN, A. P.; MÁRQUEZ, F. P. G. Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural network-based structure. **Renewable Energy**, v. 153, p. 334–348, 2020. ISSN 0960-1481. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960148120301701>>.
- ISLAM, M.; HASANUZZAMAN, M.; RAHIM, N. A. A comparative investigation on in-situ and laboratory standard test of the potential induced degradation of crystalline silicon photovoltaic modules. **Renewable Energy**, v. 127, p. 102–113, 2018. ISSN 0960-1481. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960148118304592>>.
- JAFFERY, Z. A.; DUBEY, A. K.; IRSHAD; HAQUE, A. Scheme for predictive fault diagnosis in photo-voltaic modules using thermal imaging. **Infrared Physics e Technology**, v. 83, p. 182–187, 2017. ISSN 1350-4495.

JAHN, U.; HERZ, M.; PARLEVLJET, D.; PAGGI, M.; TSANAKAS, I.; STEIN, J.; BERGER, K.; RANTA, S.; FRENCH, R.; RICHTER, M. *et al.* **Review on infrared and electroluminescence imaging for PV field applications**. [S.l.: s.n.], 2018.

KARIMI, A. M.; FADA, J. S.; HOSSAIN, M. A.; YANG, S.; PESHEK, T. J.; BRAID, J. L.; FRENCH, R. H. Automated pipeline for photovoltaic module electroluminescence image processing and degradation feature classification. **IEEE Journal of Photovoltaics**, v. 9, n. 5, p. 1324–1335, 2019.

KARIMI, A. M.; FADA, J. S.; LIU, J.; BRAID, J. L.; KOYUTÜRK, M.; FRENCH, R. H. Feature extraction, supervised and unsupervised machine learning classification of pv cell electroluminescence images. In: **2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC) (A Joint Conference of 45th IEEE PVSC, 28th PVSEC e 34th EU PVSEC)**. [S.l.: s.n.], 2018. p. 0418–0424.

KETCHAM, D. J.; LOWE, R. W.; WEBER, J. W. Image enhancement techniques for cockpit displays. In: . [S.l.: s.n.], 1974.

KOCH, G.; ZEMEL, R.; SALAKHUTDINOV, R. *et al.* Siamese neural networks for one-shot image recognition. In: LILLE. **ICML deep learning workshop**. [S.l.], 2015. v. 2, n. 1.

KOHA., R. A study of crossvalidation and bootstrap for accuracy estimation and model selectivv. **Appears in the International Joint Conference on Artificial Intelligence IJCAI**, 1995.

LAKHANI, P. Deep convolutional neural networks for endotracheal tube position and x-ray image classification: Challenges and opportunities. **Journal of Digital Imaging**, v. 30, n. 4, p. 460–468, 2017.

LECUN, Y.; BOSER, B.; DENKER, J. S.; HENDERSON, D.; HOWARD, R. E.; HUBBARD, W.; JACKEL, L. D. Backpropagation Applied to Handwritten Zip Code Recognition. **Neural Computation**, v. 1, n. 4, p. 541–551, 12 1989. ISSN 0899-7667.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998.

MADETI, S. R.; SINGH, S. A comprehensive study on different types of faults and detection techniques for solar photovoltaic system. **Solar Energy**, v. 158, p. 161–185, 2017. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X17307508>>.

MADETI, S. R.; SINGH, S. Monitoring system for photovoltaic plants: A review. **Renewable and Sustainable Energy Reviews**, v. 67, p. 1180–1207, 2017. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032116305792>>.

MAI, L.; KOLIOUSIS, A.; LI, G.; BRABETE, A.-O.; PIETZUCH, P. Taming hyper-parameters in deep learning systems. **SIGOPS Oper. Syst. Rev.**, Association for Computing Machinery, New York, NY, USA, v. 53, n. 1, p. 52–58, jul 2019. ISSN 0163-5980. Disponível em: <<https://doi.org/10.1145/3352020.3352029>>.

MÁRQUEZ, F. P. G.; RAMÍREZ, I. S. Condition monitoring system for solar power plants with radiometric and thermographic sensors embedded in unmanned aerial vehicles. **Measurement**, Elsevier, v. 139, p. 152–162, 2019.

MATHIAS, N.; SHAIKH, F.; THAKUR, C.; SHETTY, S.; DUMANE, P.; CHAVAN, D. *et al.* Detection of micro-cracks in electroluminescence images of photovoltaic modules. In: **Proceedings of the 3rd International Conference on Advances in Science and Technology (ICAST)**. [S.l.: s.n.], 2020.

MAYYA, A.; ALKAYEM, N. F.; SHEN, L.; ZHANG, X.; FU, R.; WANG, Q.; CAO, M. Efficient hybrid ensembles of cnns and transfer learning models for bridge deck image-based crack detection. **Structures**, v. 64, p. 106538, 2024. ISSN 2352-0124. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352012424006908>>.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, 1943. ISSN 1522-9602. Disponível em: <<https://doi.org/10.1007/BF02478259>>.

MCHUGH, M. L. Interrater reliability: the kappa statistic. **Biochem. Med. (Zagreb)**, Croatian Society for Medical Biochemistry and Laboratory Medicine, v. 22, n. 3, p. 276–282, 2012.

MELLO, T. H. de; BAYRAKSAN, G. Monte carlo sampling-based methods for stochastic optimization. **Surveys in Operations Research and Management Science**, v. 19, n. 1, p. 56–85, 2014. ISSN 1876-7354. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1876735414000038>>.

MENG, Z.; XU, S.; WANG, L.; GONG, Y.; ZHANG, X.; ZHAO, Y. Defect object detection algorithm for electroluminescence image defects of photovoltaic modules based on deep learning. **Energy Science and Engineering**, v. 10, n. 3, p. 800–813, 2022. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/ese3.1056>>.

MUSTAFA, W. A.; KADER, M. M. M. A. A review of histogram equalization techniques in image enhancement application. **Journal of Physics: Conference Series**, IOP Publishing, v. 1019, n. 1, p. 012026, jun 2018. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/1019/1/012026>>.

MUTTILLO, M.; NARDI, I.; STORNELLI, V.; RUBEIS, T. de; PASQUALONI, G.; AMBROSINI, D. On field infrared thermography sensing for pv system efficiency assessment: Results and comparison with electrical models. **Sensors**, MDPI AG, v. 20, n. 4, p. 1055, Feb 2020. ISSN 1424-8220.

NIAZI, K. A. K.; AKHTAR, W.; KHAN, H. A.; YANG, Y.; ATHAR, S. Hotspot diagnosis for solar photovoltaic modules using a naive bayes classifier. **Solar Energy**, v. 190, p. 34–43, 2019. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X19307340>>.

PIZER, S.; JOHNSTON, R.; ERICKSEN, J.; YANKASKAS, B.; MULLER, K. Contrast-limited adaptive histogram equalization: speed and effectiveness. In: **[1990] Proceedings of the First Conference on Visualization in Biomedical Computing**. IEEE Computer Society, 1990. p. 337,338,339,340,341,342,343,344,345. Disponível em: <<https://doi.ieeecomputersociety.org/10.1109/VBC.1990.109340>>.

RAPHAEL, R.; Ellen, E.; Silva, S.; Mariana Nascimento, N. M. Células solares de perovskitas: Uma nova tecnologia emergente. **SciELO**, v. 41, n. 9, p. 61–74, 2018.

- RAZAVIAN, A. S.; AZIZPOUR, H.; SULLIVAN, J.; CARLSSON, S. Cnn features off-the-shelf: An astounding baseline for recognition. In: **2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops**. [S.l.: s.n.], 2014. p. 512–519.
- RIVAI, A.; RAHIM, N. A.; ELIAS, M. F. M.; JAMALUDIN, J. Analysis of photovoltaic string failure and health monitoring with module fault identification. **Energies**, MDPI AG, v. 13, n. 1, p. 100, Dec 2019. ISSN 1996-1073.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958. ISSN 0033-295X.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of Big Data**, v. 6, n. 1, p. 60, jul. 2019.
- SOMBRIO, G.; FRANZEN, P. L.; MALTEZ, R. L.; MATOS, L. G.; PEREIRA, M. B.; BOUDINOV, H. Photoluminescence from sinxoy films deposited by reactive sputtering. **Journal of Physics D: Applied Physics**, IOP Publishing, v. 46, n. 23, p. 235106, may 2013.
- STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 3, p. 397–399, 1985.
- Sánchez-Pacheco, F. J.; Sotorri o-Ruiz, P. J.; Heredia-Larrubia, J. R.; P erez-Hidalgo, F.; de Cardona, M. S. Plc-based pv plants smart monitoring system: Field measurements and uncertainty estimation. **IEEE Transactions on Instrumentation and Measurement**, v. 63, n. 9, p. 2215–2222, 2014.
- TANG, W.; YANG, Q.; HU, X.; YAN, W. Convolution neural network based polycrystalline silicon photovoltaic cell linear defect diagnosis using electroluminescence images. **Expert Systems with Applications**, v. 202, p. 117087, 2022.
- TANG, W.; YANG, Q.; XIONG, K.; YAN, W. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images. **Solar Energy**, v. 201, p. 453–460, 2020.
- TSANAKAS, J. A.; HA, L.; BUERHOP, C. Faults and infrared thermographic diagnosis in operating c-si photovoltaic modules: A review of research and future challenges. **Renewable and Sustainable Energy Reviews**, v. 62, p. 695–709, 2016. ISSN 1364-0321. Dispon vel em: <<https://www.sciencedirect.com/science/article/pii/S1364032116301629>>.
- VERGURA, S.; MARINO, F. Quantitative and computer-aided thermography-based diagnostics for pv devices: Part i—framework. **IEEE Journal of Photovoltaics**, v. 7, n. 3, p. 822–827, 2017.
- VIEIRA, P.; SOUSA, O.; MAGALH ES, D.; RAB ELO, R.; SILVA, R. Detecting pulmonary diseases using deep features in x-ray images. **Pattern Recognition**, v. 119, p. 108081, 2021. ISSN 0031-3203. Dispon vel em: <<https://www.sciencedirect.com/science/article/pii/S0031320321002685>>.
- VIEIRA, P.; SOUSA, O.; MAGALH ES, D.; RAB ELO, R.; SILVA, R. Detecting pulmonary diseases using deep features in x-ray images. **Pattern Recognition**, v. 119, p. 108081, 2021. ISSN 0031-3203. Dispon vel em: <<https://www.sciencedirect.com/science/article/pii/S0031320321002685>>.

VIEIRA, P. A.; MAGALHÃES, D. M.; CARVALHO-FILHO, A. O.; VERAS, R. M.; RABÊLO, R. A.; SILVA, R. R. Classification of covid-19 in x-ray images with genetic fine-tuning. **Computers and Electrical Engineering**, v. 96, p. 107467, 2021. ISSN 0045-7906. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045790621004249>>.

VOGADO, L. H.; VERAS, R.; AIRES, K. “leuknet” - um modelo de rede neural convolucional para o diagnóstico de leucemia. In: . [S.l.: s.n.], 2021. p. 85–90.

WAIBEL, A.; HANAZAWA, T.; HINTON, G.; SHIKANO, K.; LANG, K. Phoneme recognition using time-delay neural networks. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 37, n. 3, p. 328–339, 1989.

WALT, S. van der; SCHÖNBERGER, J. L.; Nunez-Iglesias, J.; BOULOGNE, F.; WARNER, J. D.; YAGER, N.; GOUILLART, E.; YU, T.; CONTRIBUTORS the scikit-image. scikit-image: image processing in Python. **PeerJ**, v. 2, p. e453, 6 2014. ISSN 2167-8359. Disponível em: <<https://doi.org/10.7717/peerj.453>>.

WHITLEY, D.; DZUBERA, S. R. and J.; MATHIAS, K. E. Evaluating evolutionary algorithms. **Artificial Intelligence**, v. 85, n. 1, p. 245–276, 1996. ISSN 0004-3702.

WISMÜLLER, A.; VIETZE, F.; DERSCH, D. R. 7 - segmentation with neural networks. In: BANKMAN, I. N. (Ed.). **Handbook of Medical Imaging**. San Diego: Academic Press, 2000, (Biomedical Engineering). p. 107–126. ISBN 978-0-12-077790-7. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780120777907500114>>.

YAMASHITA, R.; NISHIO, M.; DO, R. K. G.; TOGASHI, K. Convolutional neural networks: an overview and application in radiology. **Insights into Imaging**, v. 9, n. 4, p. 611–629, 2018. ISSN 1869-4101. Disponível em: <<https://doi.org/10.1007/s13244-018-0639-9>>.

YI, Z.; ETEMADI, A. H. Line-to-line fault detection for photovoltaic arrays based on multiresolution signal decomposition and two-stage support vector machine. **IEEE Transactions on Industrial Electronics**, v. 64, n. 11, p. 8546–8556, 2017.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? In: . [S.l.: s.n.], 2014. (NIPS’14), p. 3320–3328.

YOUNG, S. R.; ROSE, D. C.; KARNOWSKI, T. P.; LIM, S.-H.; PATTON, R. M. Optimizing deep learning hyper-parameters through an evolutionary algorithm. In: . Association for Computing Machinery, 2015. ISBN 9781450340069. Disponível em: <<https://doi.org/10.1145/2834892.2834896>>.

ZUBEN, F. J. V. **Computação Evolutiva: Uma Abordagem Pragmática**. [S.l.]: DCA/FEEC/Unicamp, 2009.