



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS SOBRAL
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

FRANCILÂNDIO LIMA SERAFIM

DETECÇÃO AUTOMÁTICA DE DEFEITOS EM CÉLULAS FOTOVOLTAICAS
ATRAVÉS DE REDES NEURAIIS CONVOLUCIONAIS

SOBRAL

2023

FRANCILÂNDIO LIMA SERAFIM

DETECÇÃO AUTOMÁTICA DE DEFEITOS EM CÉLULAS FOTOVOLTAICAS ATRAVÉS
DE REDES NEURASIS CONVOLUCIONAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Marcelo Marques Simões de Souza

SOBRAL

2023

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)

L698d Lima Serafim, Francilândio.
Detecção Automática de Defeitos em Células Fotovoltaicas Através de Redes Neurais Convolucionais / Francilândio Lima Serafim. – 2023.
46 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Sobral, Curso de Engenharia da Computação, Sobral, 2023.
Orientação: Prof. Dr. Marcelo Marques Simões de Souza.

1. Rede Neural Convolucional Customizada. 2. Célula fotovoltaica. 3. Detecção de defeitos. Eletroluminescência. 4. Padrão Binário Local. I. Título.

CDD 621.39

FRANCILÂNDIO LIMA SERAFIM

DETECÇÃO AUTOMÁTICA DE DEFEITOS EM CÉLULAS FOTOVOLTAICAS ATRAVÉS
DE REDES NEURAIAS CONVOLUCIONAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do *Campus* Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Aprovada em: 07 de Dezembro de 2023

BANCA EXAMINADORA

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

Eng. Eletricista Alan Marques da Rocha
Universidade Federal do Ceará

Prof. Me. David Nascimento Coelho
Universidade Federal do Ceará

Dedico este trabalho ao meu pai, Francisco Gonçalves Serafim, e à minha mãe, Maria Lúcia de Lima.

AGRADECIMENTOS

Ao meu pai, Francisco Gonçalves, e minha mãe, Maria Lúcia, por toda a educação que me deram e por me darem todo o suporte necessário nessa jornada.

Ao Prof. Dr. Marcelo Marques Simões de Souza pela orientação e pelos ensinamentos e ao Eng. Eletricista Alan Marques da Rocha pela inspiração desse projeto.

À minha namorada, Daisa, pelos cuidados que teve comigo durante essa etapa de minha vida.

Aos meus amigos de graduação, Vanessa Carvalho, Sávio Araújo, Rodrigo Rocha e Luan Gomes pelas parcerias nos trabalhos do curso e pelo companheirismo.

Aos meus amigos, Tiago Mota e Vandson Azevedo, por tornarem minha vida mais leve desde antes da graduação.

Aos professores do ensino médio, Fagner Aguiar e Geovânia Rodrigues, que me incentivaram a trilhar esse caminho, me dando uma visão de mundo diferente.

Aos professores da Universidade Federal do Ceará (UFC) pelos ensinamentos e também a todos os servidores que indiretamente contribuíram em minha formação.

“Meus filhos terão computadores, sim, mas antes terão livros. Sem livros, sem leitura, os nossos filhos serão incapazes de escrever – inclusive a sua própria história.”

(Bill Gates)

RESUMO

A crise climática observada nos últimos anos, somada ao esgotamento de combustíveis fósseis, tornou imprescindível a adoção de fontes de energia alternativas, sustentáveis e renováveis. Nesse cenário, a energia solar tem sido empregada como fonte energética para suprir a demanda global de energia elétrica. O aumento observado na geração de eletricidade solar fotovoltaica (FV) traz demandas por métodos para inspeção e manutenção dos sistemas FVs, visto que seus componentes estão sujeitos a diversos tipos de defeitos como microtrincas, sombreamento, circuitos abertos, curtos-circuitos, superaquecimento, dentre outros. Para a detecção desses defeitos foram desenvolvidas algumas técnicas como a análise da curva I-V e inspeção de imagens térmicas ou de Eletroluminescência (EL) das células FVs. Essa última vem sendo abordada em diversos trabalhos que buscam automatizar a detecção de defeitos através de técnicas de visão computacional e aprendizado de máquina. O presente trabalho segue essa linha de pesquisa, buscando automatizar a detecção de defeitos em células FVs monocristalinas através de imagens de EL. É proposto aqui um modelo computacional de três etapas: pré-processamento, extração de características e diagnóstico de defeitos. No pré-processamento aplica-se um filtro Gaussiano Bilateral às imagens, para então obter-se, durante a fase de extração de características, um descritor de textura das imagens pelo Padrão Binário Local (PBL). Por fim, as descrições da textura das imagens resultantes alimentam uma Rede Neural Convolutiva Customizada (RNCC), treinada e testada na tarefa de classificação de células em defeituosas ou não defeituosas, na fase de diagnóstico de defeitos. A RNCC é a principal contribuição do presente trabalho, sendo essa composta por uma topologia com número reduzido de parâmetros, quando comparada a outras redes tradicionais. O desempenho obtido em testes de validação cruzada comprovaram que a rede convolutiva proposta é competitiva em relação a outras abordagens presentes na literatura. Concluiu-se então que o modelo atende às necessidades do problema de detecção de defeitos em células FVs, com acurácias de 94% e 86% na classificação de células defeituosas e não defeituosas, respectivamente.

Palavras-chave: Rede Neural Convolutiva Customizada. Célula fotovoltaica. Detecção de defeitos. Eletroluminescência. Padrão Binário Local.

ABSTRACT

The climate crisis observed in recent years, coupled with the depletion of fossil fuels, has made the adoption of alternative, sustainable and renewable energy sources imperative. In this scenario, solar energy has been employed as an energy source to meet the global demand for electric power. The observed increase in photovoltaic (PV) solar electricity generation brings demands for methods for inspecting and maintaining PV systems, as their components are subject to various types of defects such as microcracks, shading, open circuits, short circuits, overheating, among others. For the detection of these defects, some techniques have been developed such as the analysis of the I-V curve and inspection of thermal images or Electroluminescence (EL) of PV cells. The latter has been addressed in several works that seek to automate defect detection through computer vision techniques and machine learning. The present work follows this line of research, seeking to automate the detection of defects in monocrystalline PV cells through EL images. A three-step computational model is proposed here: pre-processing, feature extraction, and defect diagnosis. In pre-processing, a Bilateral Gaussian filter is applied to the images, to then obtain, during the feature extraction phase, a texture descriptor of the images by the Local Binary Pattern (LBP). Finally, the descriptions of the texture of the resulting images feed a Customized Convolutional Neural Network (CCNN), trained and tested in the task of classifying cells as defective or non-defective, in the defect diagnosis phase. The CCNN is the main contribution of the present work, being composed of a topology with a reduced number of parameters, when compared to other traditional networks. The performance obtained in cross-validation tests proved that the proposed convolutional network is competitive in relation to other approaches present in the literature. It was concluded that the model meets the needs of the problem of defect detection in PV cells, with accuracies of 94% and 86% in the classification of defective and non-defective cells, respectively.

Keywords: Customized Convolutional Neural Network. Photovoltaic Cell. Defect Detection. Electroluminescence. Local Binary Pattern.

LISTA DE FIGURAS

Figura 1 – Crescimento da capacidade global de energia renovável.	14
Figura 2 – Participação da capacidade de energia acumulada por tecnologia (%), em 2010-2027.	15
Figura 3 – A capacidade instalada de energia solar FV (GW) no mundo até 2050.	16
Figura 4 – Diagrama de um sistema FV.	24
Figura 5 – Imagem de EL, térmica e visual.	25
Figura 6 – diodos de <i>bypass</i> em um arranjo de células FVs.	26
Figura 7 – Diferentes estados de iluminação e sombreamento de uma célula FV.	27
Figura 8 – a) Sombreamento causado pela deposição de neve, b) Sombreamento causado por arvoredos próximos.	27
Figura 9 – Hotspots identificados em imagens de EL e térmicas.	28
Figura 10 – a) Célula FV de <i>Si – m</i> com <i>hotspot</i> , b) Célula FV de <i>Si – p</i> com <i>hotspot</i>	28
Figura 11 – Esquema de obtenção das imagens de EL.	29
Figura 12 – Exemplo de convolução.	31
Figura 13 – Exemplo de <i>MaxPooling</i>	33
Figura 14 – Células de <i>Si</i> (a) e (b) Condições normais de funcionamento. (c) Defeito ocasionado por trincas. (d) Elevado grau de sombreamento.	34
Figura 15 – Modelo para detecção de defeitos em células FVs a partir de imagens de EL.	35
Figura 16 – (a) Imagem original. (b) Imagem em níveis de cinza. (c) Resultado da aplicação do filtro Gaussiano Bilateral.	36
Figura 17 – Método da extração de atributos LBP.	37
Figura 18 – Imagens de células FVs e o resultado da aplicação do <i>Uniform-Local Binary Pattern</i> (U-LBP).	38
Figura 19 – Topologia da Rede Neural Convolutacional Customizada.	38

LISTA DE TABELAS

Tabela 1 – Matriz de confusão das predições realizadas pelo modelo.	40
Tabela 2 – Resultado do modelo proposto e de outros trabalhos.	40

LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i>
AP	Aprendizado Profundo
CCNN	<i>Custom Convolutional Neural Network</i>
CNN	<i>Convolutional Neural Network</i>
CNN-ILD	<i>Convolutional Neural Network - Independent Light-Depth</i>
DL	<i>Deep Learning</i>
DNN	<i>Deep Neural Network</i>
EL	Eletroluminescência
FPN	<i>Feature Pyramid Network</i>
FV	fotovoltaica
GLCM	<i>Gray Level Co-occurrence Matrix</i>
GPU	<i>Graphics Processing Unit</i>
GRL	<i>Gradient Reversal Layer</i>
IoT	<i>Internet of Things</i>
IR-LBP	<i>Invariant to Rotation-Local Binary Pattern</i>
k-NN	<i>k-Nearest Neighbors</i>
LBP	<i>Local Binary Pattern</i>
LSTM	<i>Long Short-Term Memory</i>
ML	<i>Machine Learning</i>
NB	<i>Naive Bayes</i>
PID	<i>Potencial Induced Degradation</i>
ReLU	<i>Rectified Linear Unit</i>
RF	<i>Random Forest</i>
SPP	<i>Spatial Pyramid Pooling</i>
SVM	<i>Support Vector Machine</i>
U-LBP	<i>Uniform-Local Binary Pattern</i>
UIR-LBP	<i>Uniform and Invariant to Rotation-Local Binary Pattern</i>

LISTA DE SÍMBOLOS

<i>TWh</i>	Terawatt-hora
<i>GW</i>	Gigawatt
<i>Si – m</i>	Silício monocristalino
<i>Si – p</i>	Silício policristalino
<i>VP</i>	Verdadeiro Positivo
<i>VN</i>	Verdadeiro Negativo
<i>FP</i>	Falso Positivo
<i>FN</i>	Falso Negativo
<i>P</i>	<i>Pooling Layer</i>
<i>C</i>	<i>Convolution Layer</i>
<i>FC</i>	<i>Fully Connected Layer</i>
<i>A_c</i>	Acurácia
<i>S_e</i>	Sensibilidade
<i>E_s</i>	Especificidade

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	17
<i>1.1.1</i>	<i>Objetivo Geral</i>	<i>17</i>
<i>1.1.2</i>	<i>Objetivos Específicos</i>	<i>17</i>
1.2	Trabalhos Relacionados	18
1.3	Organização do trabalho	23
2	FUNDAMENTAÇÃO TEÓRICA	24
2.1	Defeitos em células fotovoltaicas	24
<i>2.1.1</i>	<i>Microtrincas</i>	<i>25</i>
<i>2.1.2</i>	<i>Sombreamento</i>	<i>25</i>
<i>2.1.3</i>	<i>Pontos quentes</i>	<i>27</i>
2.2	Eletroluminescência	27
<i>2.2.1</i>	<i>Imagens de Eletroluminescência</i>	<i>29</i>
2.3	Aprendizado Profundo	29
<i>2.3.1</i>	<i>Redes Neurais Convolucionais</i>	<i>30</i>
<i>2.3.1.1</i>	<i>Camada de Convolução</i>	<i>30</i>
<i>2.3.1.2</i>	<i>Camada de Pooling</i>	<i>32</i>
3	METODOLOGIA	34
3.1	Base de Imagens	34
3.2	Modelo Proposto	34
<i>3.2.1</i>	<i>Filtro Gaussiano Bilateral</i>	<i>35</i>
<i>3.2.2</i>	<i>Extrator de texturas LBP</i>	<i>36</i>
<i>3.2.3</i>	<i>CNN Customizada</i>	<i>38</i>
3.3	Metodologia de avaliação	39
4	RESULTADOS E DISCUSSÕES	40
5	CONCLUSÕES E TRABALHOS FUTUROS	41
5.1	Trabalhos Futuros	41
	REFERÊNCIAS	42


1 INTRODUÇÃO

A queima de combustíveis fósseis para geração de energia elétrica é um dos fatores principais que acentuam dois grandes problemas atuais: o rápido esgotamento dessas fontes (POURASL *et al.*, 2023) e o aquecimento global (JIN *et al.*, 2023). Faz-se portanto necessária a adoção de fontes de energia renováveis e limpas para suprir a demanda global energética de forma sustentável.

A energia solar é considerada a principal candidata a substituir os combustíveis fósseis, por ser amplamente distribuída, sustentável e renovável (POURASL *et al.*, 2023). Apesar de sua baixa contribuição na produção global de eletricidade, a energia solar se estabeleceu perante outras tecnologias de energia renovável, acumulando cerca de 31% da capacidade total instalada de energia renovável em 2022 (IRENA, 2023). A capacidade de energia solar instalada em 2022 totalizou 1053 GW sendo a segunda tecnologia de energia renovável mais instalada, atrás apenas da hidrelétrica com 1392 GW (IRENA, 2023), indicando o grande potencial dessa tecnologia para suprir as necessidades energéticas globais.

A Figura 1 apresenta dois gráficos relacionados ao crescimento da capacidade global de energia de fontes renováveis, em que é evidenciado no gráfico da esquerda o aumento da capacidade de energia solar a cada ano desde 2017 até 2022. Também é possível observar no gráfico *Capacity added in 2022* que o aumento da capacidade da energia solar em 2022 foi maior que o das demais fontes renováveis, com um total de 192 GW.


Figura 1 – Crescimento da capacidade global de energia renovável.



Fonte: IRENA (2023).

Os sistemas de geração de energia fotovoltaica (FV) tem como principal componente as células FVs sendo mais utilizada que a solar térmica, em partes, por conta da sua maior facilidade no processo de obtenção da energia elétrica (ECOFLOW, 2023) e a alta disponibilidade da matéria-prima usada na fabricação de células FVs de silício cristalino (GHOSH *et al.*, 2023). Estes fatos somados aos demais supracitados justificam a previsão de IEA (2022b), que indica a superação da capacidade de energia instalada do carvão pela da energia solar FV até 2027 tornando-se a maior do mundo. Além disso estima-se que nas próximas três décadas o campo solar FV pode se tornar a segunda fonte de geração proeminente possibilitando que os países gerem cerca de 25% das necessidades totais de eletricidade do mundo até 2050 (POURASL *et al.*, 2023), evidenciando um maior investimento na tecnologia de sistemas FVs globalmente. A Figura 2 ilustra a previsão do crescimento da capacidade de energia solar FV instalada no mundo comparando-se com outros tipos de energia como a produzida pelo carvão, gás natural, hidrelétrica, eólica e bioenergia no período de 2010 a 2027. A previsão indica que a energia solar FV em 2027 terá a maior participação da capacidade de energia acumulada.

Figura 2 – Participação da capacidade de energia acumulada por tecnologia (%), em 2010-2027.

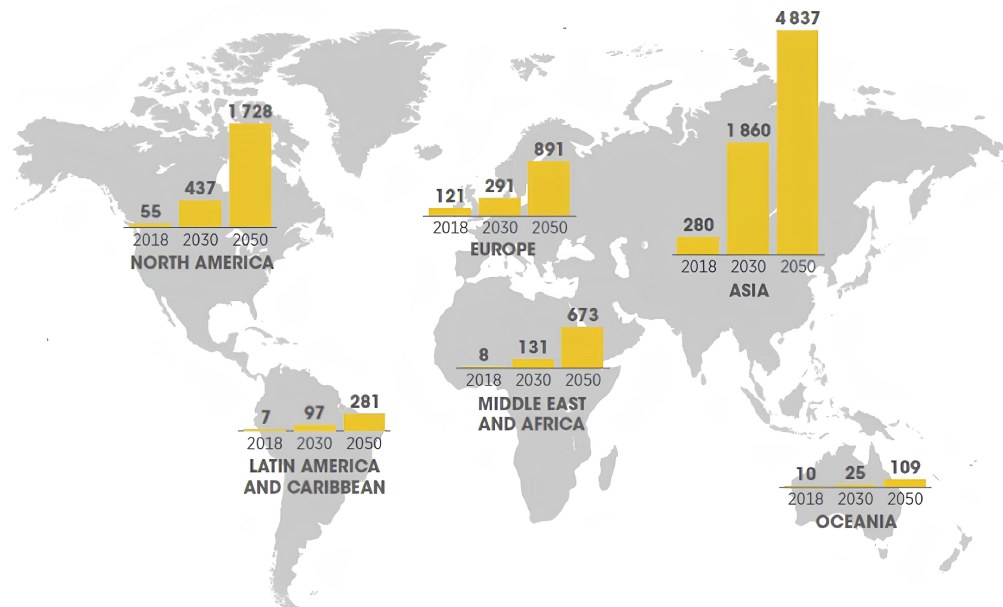


Fonte: Adaptado de IEA (2022a).

A Figura 3 apresenta a previsão da capacidade de energia solar FV instalada em cada continente nos anos de 2018, 2030 e 2050. A perspectiva é que essa tecnologia mantenha um caráter crescente de aderência global chegando a 1728, 891, 4837, 281, 673 e 109 GW de capacidade instalada na América do Norte, Europa, Ásia, América Latina e Caribe, Oriente

Médio e África e Oceania, respectivamente, em 2050.

Figura 3 – A capacidade instalada de energia solar FV (GW) no mundo até 2050.



Fonte: Pourasl *et al.* (2023).

O crescimento da tecnologia solar FV torna necessário que a geração de energia solar FV seja eficiente e, para manter a eficiência de um sistema FV, é necessário que sejam feitas inspeções e manutenções periódicas, visto que há exposição a fatores diversos que podem degradar suas células FVs tais como salinidade, chuva, poeira e vento (KIM *et al.*, 2017). Algumas técnicas usadas para diagnosticar a necessidade ou não de manutenção em sistemas FVs consistem em testes de curva I-V ou ainda através da análise de imagens térmicas/infravermelhas (IR) (Munawer Al-Otum, 2023). A abordagem de análise da curva I-V falha na detecção e localização de pequenos defeitos como microtrincas, porém é útil na determinação da eficiência do sistema FV (Munawer Al-Otum, 2023). Já a análise por imagens IR em que o painel FV é fotografado a partir de uma câmera térmica, tem grande potencial na detecção de falhas onde a temperatura é alta devido a fatores como curtos-circuitos (ET-TALEBY *et al.*, 2022), porém esse método é restrito à detecção anômala de temperatura sendo incapaz de determinar o tipo de um eventual defeito, além de ser incapaz de detectar microtrincas visto que, nesse caso, nenhuma temperatura anormal pode ser observada (TANG *et al.*, 2020).

Um método alternativo usado para detecção de defeitos é pela inspeção das imagens de eletroluminescência (EL) das células FVs (TANG *et al.*, 2020). A obtenção de imagens de EL é feita a partir da estimulação por uma fonte de tensão na célula FV, que por sua vez emite fótons que são captados por câmeras sensíveis ao comprimento de onda dos mesmos (FRAZAO

et al., 2017). Um indício de que uma determinada célula está com defeito é a redução ou perda total de emissão de radiação de EL, indicada por regiões escuras nas imagens (DJORDJEVIC *et al.*, 2014).

O presente trabalho propõe um modelo de detecção automática de defeitos em células FVs de silício monocristalino ($Si - m$), classificando-as em defeituosas ou não defeituosas. Uma Rede Neural Convolutiva Customizada (do inglês, *Custom Convolutional Neural Network* (CCNN)) foi desenvolvida sendo treinada e validada a partir de uma base de imagens de EL. Inicialmente as imagens são pré-processadas através da aplicação do filtro Gaussiano Bilateral e do método *Local Binary Pattern* (LBP) responsáveis por suavizar mantendo as informações das bordas e extrair atributos de textura das imagens, respectivamente. Após o pré-processamento, as imagens resultantes alimentam a CCNN nas etapas de treino e teste.

1.1 Objetivos

1.1.1 Objetivo Geral

Este trabalho tem como principal objetivo o desenvolvimento e validação de um modelo de CCNN para a detecção automática de defeitos em células FVs de modo a classificá-las em defeituosas ou não defeituosas.

1.1.2 Objetivos Específicos

Os objetivos específicos do presente trabalho são:

- Realizar uma revisão bibliográfica sobre as técnicas existentes para a detecção de defeitos em células FVs.
- Compreender e explicar o funcionamento das *Convolutional Neural Network* (CNN)s e como elas podem ser aplicadas na detecção de defeitos.
- Propor um modelo de CNN para a detecção de defeitos em células FVs tais como microtrincas, pontos quentes (*hotspots*) e sombreamento.
- Avaliar o desempenho do modelo proposto em termos de precisão, acurácia e outras métricas relevantes.
- Comparar o desempenho do modelo proposto com outras técnicas existentes na literatura.

1.2 Trabalhos Relacionados

Em busca de aprimorar as técnicas existentes para detecção de defeitos em módulos FVs muitos trabalhos têm sido desenvolvidos visando a automação dessa tarefa. A seguir, são mencionados alguns artigos que descrevem abordagens usando algoritmos de *Deep Learning* (DL) e *Machine Learning* (ML).

Deitsch *et al.* (2019) investigaram duas abordagens para a detecção automática de defeitos através de imagens de células FVs. A primeira abordagem é baseada no classificador clássico *Support Vector Machine* (SVM). A segunda abordagem usa uma CNN que roda em uma *Graphics Processing Unit* (GPU). Ambas as abordagens foram treinadas usando a base pública de Buerhop-Lutz *et al.* (2018), da qual foram usadas 1968 imagens de EL de células FVs mono e policristalinas de alta resolução. A CNN atingiu uma acurácia média de 88,42%, enquanto a SVM alcançou uma acurácia média ligeiramente menor de 82,44%. Os autores concluíram que as abordagens tornam viável o monitoramento contínuo e altamente preciso das células FVs, sendo o classificador SVM mais viável para aplicações que demandam menor disponibilidade de recursos

Akram *et al.* (2019) realizaram uma investigação envolvendo diferentes arquiteturas de CNNs incluindo VGG19, VGG16, VGG13 e VGG11 com intuito de propor uma arquitetura leve com equilíbrio entre bom desempenho e baixo custo computacional para detectar defeitos em células FVs. A base de Buerhop-Lutz *et al.* (2018) foi utilizada sendo nela aplicado aumento de dados para evitar *overfitting* no treinamento. A abordagem apresentada pelos autores alcançou resultados de 93,02% de acurácia, mostrando-se competitivo em relação a outros modelos comparados usando o mesmo conjunto de dados tendo como diferencial o baixo custo computacional empregado.

Korkmaz e Acikgoz (2022) desenvolveram um método para classificação de falhas em módulos FVs usando CNN em multi-escala com três ramos baseados na estratégia de aprendizado por transferência. Os autores propuseram detectar e classificar 11 tipos de falhas em módulos FVs incluindo rachaduras, pontos quentes, falhas de diodos, sombreamento, etc. através de imagens termográficas de uma base pública composta por 20000 amostras. Para contornar o problema do desbalanceamento das classes, utilizaram aumento de dados de modo a equilibrar a quantidade de amostras de cada tipo de defeito. O modelo de rede neural proposto foi desenvolvido a partir da arquitetura AlexNet pré-treinada, os dados aumentados foram usados em seu treinamento, teste e validação e seus resultados foram comparados com os de outras redes

pré-treinadas como AlexNet, SqueezeNet e ShuffleNet. Foram feitos dois tipos de experimentos na avaliação do modelo, um considerava 2 classes sendo de módulos defeituosos e sem defeitos e outro considerava a classificação dos 11 tipos de defeitos resultando em uma acurácia média de 97,32% para o primeiro experimento e 93,51% para o segundo. Os autores concluíram através dos experimentos que o método proposto oferece maior precisão e robustez na classificação de falhas nos painéis FVs e supera outros métodos de aprendizado profundo e estudos existentes.

Et-taleby *et al.* (2022) propôs um modelo de detecção e classificação de falhas em imagens de EL de painéis FVs que combina CNN e *Support Vector Machine* (SVM) utilizados, respectivamente, para extração e classificação de atributos. No trabalho desenvolvido foram utilizadas duas bases de imagens D1 e D2 para treino e validação, e ao comparar o modelo proposto com os de trabalhos similares foi constatado um desempenho de classificação superior com a precisão de 99,49% e 99,46% para as bases D1 e D2, respectivamente.

Rocha *et al.* (2023) apresentaram uma metodologia de detecção de defeitos em células FVs utilizando técnicas de visão computacional. A identificação dos defeitos foi realizada através da análise de atributos de textura, que são calculados a partir da *Gray Level Co-occurrence Matrix* (GLCM) das imagens das células. A eficácia desta abordagem foi validada através de testes usando a base de imagens de Buerhop-Lutz *et al.* (2018), onde o classificador *Random Forest* (RF) demonstrou a melhor acurácia (90%) dentre outros três testados. Os autores concluíram que o modelo proposto é uma alternativa viável na inspeção automatizada de células FVs.

Munawer Al-Otum (2023) desenvolveram uma abordagem de detecção e classificação de falhas em módulos FVs através da análise de imagens de EL da base ELPV explorando dois cenários, o primeiro com transferência de aprendizado usando duas *Deep Neural Network* (DNN)s (ResNet18 e ShuffleNet) e o segundo com o uso de uma CNN independente de profundidade leve (do inglês, *Convolutional Neural Network - Independent Light-Depth* (CNN-ILD)). Na detecção de defeitos sem necessidade de classificação, a CNN-ILD foi superior em termos de acurácia, precisão, *recall* e *F1-score* (maiores que 99,8%). Em relação ao desempenho na classificação de falhas, as DNNs propostas tiveram melhor resultado com precisão média entre (88,41-90,89%) e (94,31-98,05%) alcançada em testes envolvendo 4 e 8 classes, respectivamente. Os autores concluíram que a CNN-ILD mostrou-se vantajosa em termos do poder/tempo computacional e estabilidade sobre as outras duas DNNs pré-treinadas propostas. Isso sugere que a abordagem proposta pode ser uma ferramenta eficaz para a detecção e classificação de falhas em

células FVs.

Sohail *et al.* (2023) objetivaram a identificação automática de alguns tipos de fissuras em células FVs. Para isso, um método de DL foi proposto usando quatro modelos sendo U-net, LinkNet, *Feature Pyramid Network* (FPN) e *attention* U-net sendo treinados, avaliados e comparados usando uma base pública de imagens de EL. Os resultados experimentais mostraram que a *attention* U-net superou os outros três modelos, U-net ficou em segundo lugar e LinkNet ficou em último. Para melhorar ainda mais os resultados e alcançar uma média de alta eficiência, o método de *ensemble* foi aplicado aos modelos treinados. Os autores concluíram que a metodologia proposta supera as limitações dos métodos tradicionais de monitoramento e oferece uma solução mais precisa e robusta.

Hassan e Dhimish (2023) desenvolveram um método automático de detecção de defeitos em módulos FVs com foco em trincas, microtrincas, degradação induzida por potencial (do inglês, *Potencial Induced Degradation* (PID)) e áreas sombreadas. A abordagem adotada é de inspecionar imagens de EL através de CNNs sendo executados dois níveis de inspeção, a saber: inspeção em nível de célula e inspeção em nível de módulo. Os autores analisam separadamente cada célula de um módulo e dependendo do percentual de células defeituosas determinam o grau de integridade do módulo. As CNNs usadas foram implementadas do zero divergindo entre si principalmente pelo número de camadas convolucionais e o tipo de *pooling*. A arquitetura intitulada Arch 4 obteve o melhor desempenho atingindo uma precisão de validação de 98,07%. O sistema proposto foi validado em um estudo de caso para instalações FVs com defeito por PID, onde identificou todos os módulos defeituosos com um alto grau de precisão de 96,6%, superando os métodos existentes e evidenciando que sua integração em linhas de montagem de fabricação FV tem um enorme potencial para identificação de defeitos em tempo real, contribuindo assim para a produção de células FVs de maior qualidade.

Bakır *et al.* (2023) propuseram uma abordagem baseada em uma CNN para detecção automática de defeitos em módulos FVs usando imagens termográficas com foco em falhas de ponto quente. A rede neural proposta foi treinada e validada com conjuntos de 300, 500 e 1000 imagens de módulos FVs tendo como tarefa aprender a classificá-los como *operative* (sem defeitos) ou *hotspot* (defeituoso) e comparada a outra rede neural de memória de longo prazo (do inglês, *Long Short-Term Memory* (LSTM)) obtendo como resultado uma melhor performance por parte da CNN proposta. Ambas as redes foram avaliadas com um conjunto de imagens antes e depois da aplicação de uma técnica para aumento de dados, de modo que três testes realizados

após o aumento identificaram a CNN proposta como mais precisa tendo obtido acurácias de 87,84%, 86,42% e 95,05% contra 70,16%, 77,82% e 78,39% de acurácias obtidas pela rede LSTM. Os autores concluíram que o modelo de CNN proposto tem boa precisão (acurácia média de 95,05%) e desse modo é uma ferramenta útil se acoplada a ensaios termográficos não destrutivos alinhados ao uso de veículos de campo não tripulados, pois economiza tempo ao permitir que mais módulos FVs sejam inspecionados do que o mesmo ensaio realizado em solo por um operador caracterizado.

Cao *et al.* (2023) se propuseram a atacar o problema da detecção de defeitos em painéis solares usando um algoritmo melhorado baseado no YOLO-v5, chamado YOLOv5s-GBC. Para verificar a eficácia do método proposto eles usaram a base de imagens de EL fornecida pela 35^a Conferência e Exposição Europeia de Energia Solar Fotovoltaica. Os resultados experimentais indicam que o YOLOv5s-GBC é superior a versão original do algoritmo apresentando um aumento da precisão e velocidade de inferência de 2% e 20%, respectivamente. Os autores concluíram que o modelo proposto apresenta desempenho competitivo na tarefa de detecção de defeitos sendo tão precisa quanto outras técnicas usadas, além disso ele pode ser usado na inspeção de instalações FVs para melhorar a qualidade da geração de energia FV em edifícios por exemplo.

Xie *et al.* (2023) utilizaram uma ResNet-50 pré-treinada com a base ImageNet para automatizar a detecção de defeitos em células de silício mono e policristalino através de imagens de EL. Os autores destacaram um problema de que como os tipos de células têm morfologias distintas, uma mesma CNN que se proponha a detectar falhas em ambos pode ter sua eficiência comprometida, então para contornar o problema a abordagem adotada foi treinar a rede neural com imagens rotuladas de células de silício monocristalino e usar transferência de aprendizado pelo método *Gradient Reversal Layer* (GRL) para que a rede consiga rotular imagens de células de silício policristalino. A técnica de aprendizado adversarial também foi incorporada à rede, onde o discriminador de domínio foi adicionado para distinguir domínios de dados, para que o extrator de recursos possa aprender recursos invariantes de domínio. A abordagem desenvolvida obteve *recall* de 84,70% e precisão de 90,15% na tarefa de detecção de microtrincas em células FVs de silício mono e policristalino.

A partir da análise de imagens de EL, Acikgoz *et al.* (2023) propuseram um método de detecção de defeitos usando Inception-v3 baseado em conexão residual com estrutura *Spatial Pyramid Pooling* (SPP) (Res-Inc-v3-SPP). Para evitar *overfitting* devido ao desbalanceamento

das classes de imagens e à pequena quantidade de amostras, foi aplicada uma técnica de aumento de dados. O método proposto foi avaliado em um conjunto de imagens pública de 8 classes, das quais 7 classes são de células defeituosas e uma classe de células funcionais. Na avaliação comparativa, enquanto outras abordagens obtiveram precisão entre 76,49% e 89,17%, este valor foi aumentado para 93,59% com o método proposto. Os resultados experimentais mostraram que o método proposto exibe desempenho de classificação mais preciso e robusto em comparação com outras combinações de modelos combinados e baseados em CNNs.

Zhao *et al.* (2023) desenvolveram um algoritmo inteligente (HRNet) para a detecção automática de defeitos em módulos FVs através de imagens de EL. Uma técnica de aumento de dados foi usada para expandir a base utilizada que era composta por imagens de células de silício mono e policristalino, defeituosas e funcionais. Um algoritmo de identificação adaptado ao modelo de imagem, chamado de rede de auto-fusão (SeFNet), foi utilizado para substituir a camada de classificação da HRNet. Para avaliar o modelo proposto os autores fizeram comparações com outras abordagens existentes que utilizaram o mesmo conjunto de dados, concluindo a superioridade do modelo proposto em termos de desempenho com 94,90% de acurácia. A conclusão do trabalho foi que os resultados experimentais mostraram que o aumento de dados é benéfico e o modelo SeF-HRNet melhorou efetivamente a precisão de identificação de defeitos em células FVs.

Abdallah *et al.* (2023) propuseram um sistema de detecção automática de defeitos em módulos FVs em que uma *Artificial Neural Network* (ANN) é responsável por detectar com precisão defeitos como sombreamento enquanto uma plataforma *Internet of Things* (IoT) permite o monitoramento remoto e a análise de dados como a potência de saída dos módulos. O método proposto prevê a potência de saída de um painel solar funcionando adequadamente sob várias condições ambientais usando ANN. Além disso, o sistema de monitoramento proposto pode registrar dados e conduzir análises usando uma interface baseada em Python, permitindo a melhoria da eficiência de geração energética e redução dos custos de manutenção.

O presente trabalho destaca como contribuição o desenvolvimento de uma topologia de rede neural convolucional denominada CCNN. A CCNN é mais competitiva em termos de desempenho e complexidade do que as topologias de rede de uso geral, como a VGG (SIMONYAN; ZISSERMAN, 2015), a Inception e ResNet (SZEGEDY *et al.*, 2016), em problemas de identificação de defeitos em células FVs.

1.3 Organização do trabalho

A divisão deste trabalho foi feita em 5 capítulos:

No Capítulo 2 são abordados conceitos que dizem respeito à fundamentação teórica do presente trabalho. As células FVs de $Si - m$ são o assunto da seção 2.1, onde são abordados alguns tipos de possíveis falhas que afetam sua eficiência. A seção 2.2 aborda o conceito de EL, que é uma propriedade importante para obtenção das imagens usadas no presente trabalho. Na seção 2.3 é apresentada uma visão geral do aprendizado profundo, sendo explicado o funcionamento das CNNs.

A metodologia empregada no presente trabalho é apresentada no Capítulo 3, onde são repassadas informações sobre a base utilizada, é explicado o pré-processamento das imagens e são descritos os parâmetros utilizados no treinamento da rede neural e sua topologia.

Os resultados obtidos no experimentos são apresentados no Capítulo 4, e também são comparados com resultados obtidos em outras abordagens sendo feita uma breve discussão a respeito.

Por fim, no Capítulo 5 são apresentadas as conclusões a partir dos resultados dos experimentos realizados, finalizando com uma proposta de trabalhos futuros com base em possíveis melhorias a serem desenvolvidas a partir do presente trabalho.

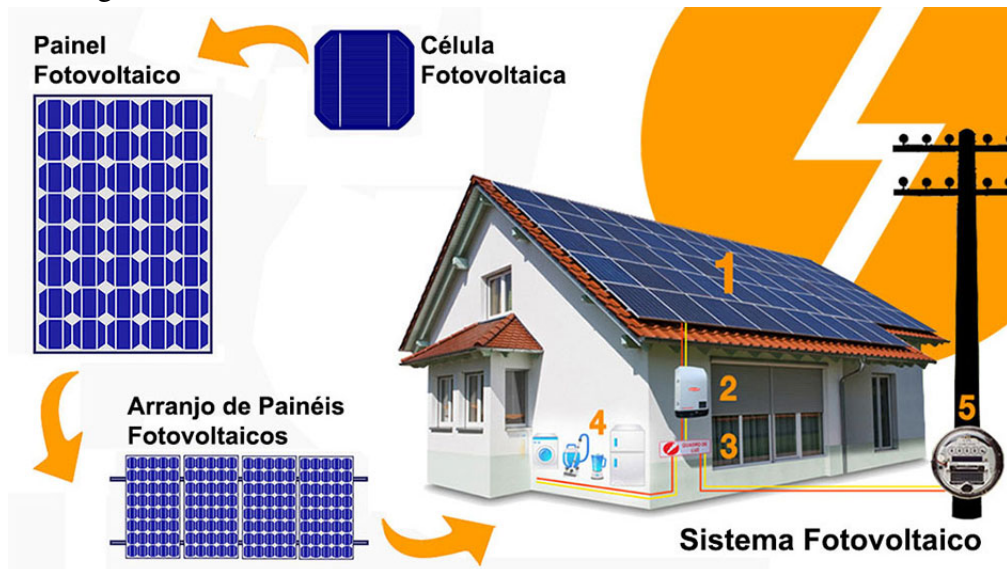
2 FUNDAMENTAÇÃO TEÓRICA

2.1 Defeitos em células fotovoltaicas

Os sistemas FVs são compostos por um arranjo de painéis/módulos FVs e outros equipamentos complementares. Painéis FVs são formados por células FVs, geralmente 60, 72 ou 96 unidades conectadas em série (GHOSH *et al.*, 2023). As células FVs tem a função de transformar a radiação solar diretamente em energia elétrica através do efeito fotovoltaico (MILES *et al.*, 2005).

A Figura 4 ilustra o esquema da composição de um sistema FV, em que um arranjo em série ou paralelo de células FVs forma um painel e um conjunto de painéis FVs, interligados em série ou paralelo, forma um arranjo de painéis. Além dos painéis, o sistema FV residencial ilustrado possui um inversor, que transforma a tensão gerada (que é gerada em corrente contínua) em corrente alternada. A energia elétrica, produzida e convertida, é conduzida ao quadro de distribuição, para então ser disponibilizada ao consumidor. Caso a energia produzida não seja suficiente para suprir as demandas da residência, a rede pública supre o excedente, e em caso de energia excedente, essa é direcionada à rede pública, gerando ao consumidor um saldo positivo na conta de energia (Sistema *on-grid*). Existem situações em que a energia produzida é armazenada em uma bateria que pode ser usada para suprir necessidades futuras (Sistema *off-grid*).

Figura 4 – Diagrama de um sistema FV.



Fonte: Blog (2018).

As células FVs podem ser compostas por um único cristal de silício (monocristalina)


ou por múltiplos cristais de silício (policristalina). Embora a última apresente menor custo de produção, seu desempenho é 14% inferior à primeira (Alexandre *et al.*, 2018). Uma vez que a ênfase deste trabalho está na detecção de defeitos em células FVs de silício monocristalino, apresentamos a seguir os principais tipos de defeitos que ocorrem nesse tipo de células.

2.1.1 Microtrincas

Microtrincas são pequenas rachaduras invisíveis a olho nu presentes nas células FVs que podem gerar problemas como perda de desempenho e elevação da resistência elétrica que leva a um aumento localizado na temperatura resultando em pontos quentes culminando até mesmo em incêndios (DHIMISH; HU, 2022). As possíveis causas desse tipo de defeito são estresse térmico ou mecânico durante o processo produtivo, transporte, instalação, manutenção, limpeza, temperaturas extremas, intempéries, entre outros (DHIMISH *et al.*, 2017).

A Figura 5 apresenta três imagens de um mesmo módulo FV, sendo elas de EL, térmica e visual, respectivamente. É possível observar que esse módulo tem várias células com microtrincas, sendo demarcadas algumas ocorrências nas regiões 1, 2, 3 e 4, possibilitando a correlação dessas regiões nas diferentes imagens. É notório que ambas as imagens de EL e térmica permitem a localização das microtrincas, e é possível notar, pela imagem térmica, a presença de uma maior temperatura nessas áreas, mostrando a relação direta entre microtrincas e pontos quentes.

Figura 5 – Imagem de EL, térmica e visual.



Fonte: Dolara *et al.* (2016).

2.1.2 Sombreamento

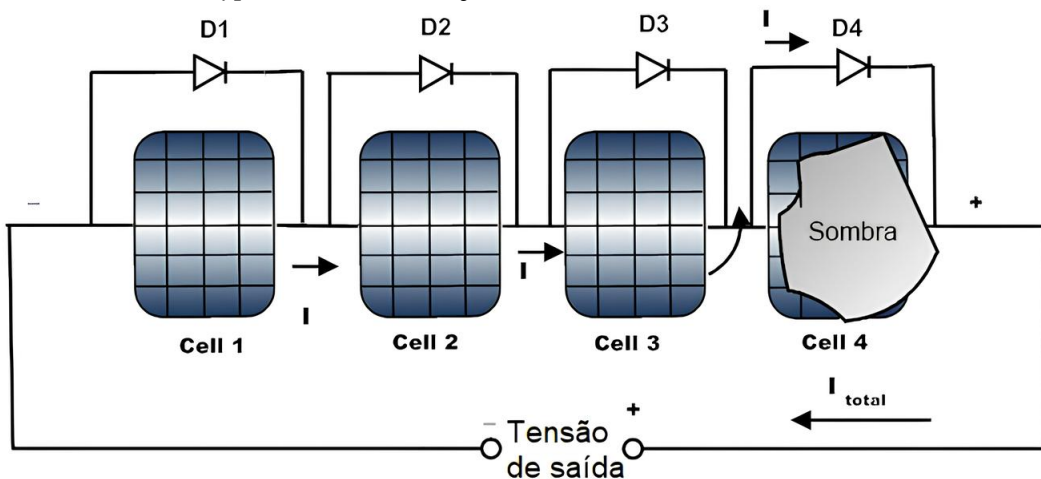
O sombreamento de células FVs causa a diminuição da incidência de luz solar e consequente perda de geração de energia elétrica de um módulo FV, comprometendo a sua eficiência. Em casos extremos, o sombreamento de uma parte do módulo pode fazê-la deixar de

ser geradora e passar a desempenhar uma função de resistência a energia (KREFT *et al.*, 2021). Diversos fatores como poeira, edifícios, árvores ou postes circundantes podem causar o problema de sombreamento (GHOSH *et al.*, 2023).

Um método usado para evitar os danos consequentes ao sombreamento de células é a aplicação de diodos de *bypass* no momento da fabricação dos módulos. Um diodo de *bypass* geralmente é conectado em paralelo a um conjunto de células conectadas em série, sua tarefa é a transmissão de corrente elétrica para fora das células em caso de seu sombreamento parcial. Devido aos diodos de *bypass*, os sistemas FVs trabalham com maior eficiência, pois os diodos protegem células individuais que trabalham em modo receptor. Os diodos de *bypass* também protegem os módulos de danos térmicos, como pontos quentes causados pela geração de calor nas células mal iluminadas como resultado da alta corrente elétrica (KREFT *et al.*, 2021).

A Figura 6 ilustra a conexão de diodos de *bypass* nas células FVs. Os diodos são conectados em paralelo com as células limitando a tensão através de uma célula ruim, permitindo que a corrente das células boas cheguem ao circuito externo, ao desviar, como neste exemplo, da célula 4 que está sombreada.

Figura 6 – diodos de *bypass* em um arranjo de células FVs.



Fonte: Adaptado de EletronicaOnline (2023).

A Figura 7 ilustra diferentes graus de iluminação e sombreamento de uma célula FV, sendo eles sem sombreamento, com sombreamento parcial e total.


A Figura 8 ilustra duas situações em que ocorrem o sombreamento parcial de um módulo FV, sendo que, na Figura 8 a), o problema é ocasionado pela deposição de neve sobre algumas células, e, na Figura 8 b), árvores próximas projetam sua sombra em algumas células.

Figura 7 – Diferentes estados de iluminação e sombreamento de uma célula FV.



Fonte: Anjos (2016).

Figura 8 – a) Sombreamento causado pela deposição de neve, b) Sombreamento causado por arvoredos próximos.



Fonte: Adaptado de Anjos (2016).

2.1.3 Pontos quentes

Pontos quentes, ou *hotspots*, são áreas de temperatura elevada que podem surgir nas células FVs devido a um sombreamento parcial ou total, sujeira ou rachaduras em um módulo FV (Waqar Akram *et al.*, 2020).

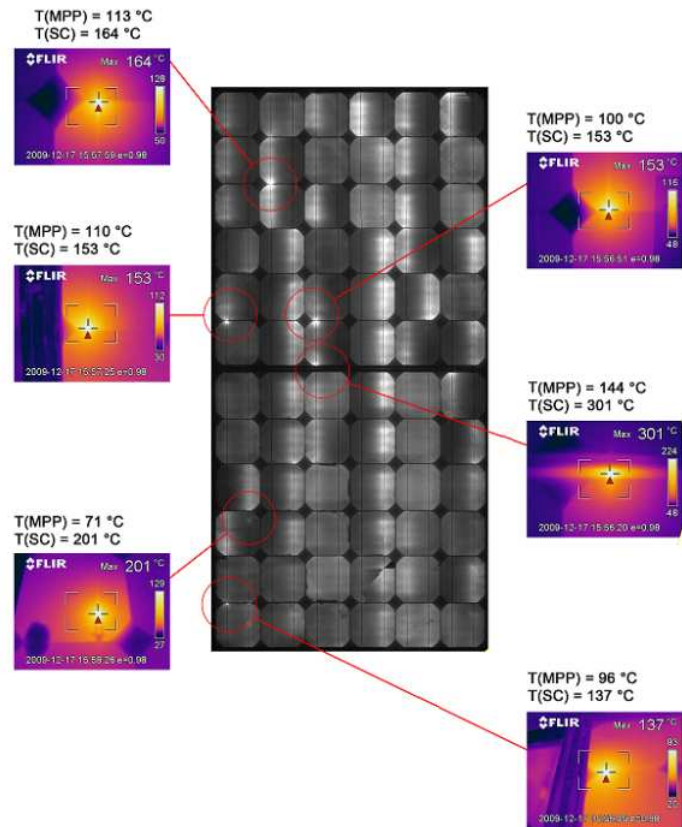
Na Figura 9 é ilustrado um módulo FV representado em uma imagem de EL tendo alguns pontos quentes circulado em vermelho, sendo essas áreas destacadas por imagens térmicas onde a temperatura se mostra mais elevada que em outros pontos das células.

A Figura 10 mostra duas células afetadas por pontos quentes através de imagens normais, sendo que, na Figura 10 a), é mostrada uma célula FV de $Si - m$ e, na Figura 10 b), é mostrada uma célula FV de $Si - p$.

2.2 Eletroluminescência


A EL é a capacidade que alguns materiais têm de produzir luz em resposta à passagem de corrente elétrica ou à presença de um forte campo elétrico, desse modo esse é um fenômeno óptico e elétrico.

Figura 9 – Hotspots identificados em imagens de EL e térmicas.



Fonte: Adaptado de solar (2011).

Figura 10 – a) Célula FV de $Si - m$ com *hotspot*, b) Célula FV de $Si - p$ com *hotspot*.



Fonte: Adaptado de Anjos (2016).

O fenômeno de EL em um material semicondutor, por exemplo, ocorre quando elétrons e lacunas se recombinam de forma radiativa. Durante esse processo, os elétrons que foram energizados liberam sua energia na forma de fótons. A separação entre elétrons e lacunas pode ser alcançada através da dopagem do material para criar uma junção p-n (como em um LED) antes da recombinação, ou pode ser resultado da excitação causada pelo impacto de elétrons de alta energia que foram acelerados por um campo elétrico intenso (Munawer Al-Otum, 2023).


Alguns dos materiais que possuem essa propriedade além de semicondutores como

silício e germânio são os metais como cobre, alumínio, prata, ouro e níquel, e compostos usados em LEDs como arsenieto de gálio, fosfato de alumínio, índio e nitreto de gálio.

2.2.1 *Imagens de Eletroluminescência*

Em condições de pouca luz, uma célula ou módulo fotovoltaico é estimulado por meio de uma fonte de corrente. Como resultado, a célula FV emite radiações no espectro infravermelho, que são registradas por uma câmera EL. As áreas defeituosas dentro de uma célula são identificadas por sua aparência mais escura na imagem de EL (PURANIK; GUPTA, 2022). A Figura 11 ilustra o esquema de obtenção de imagens de EL descrito.

Figura 11 – Esquema de obtenção das imagens de EL.



Fonte: Adaptado de Et-taleby *et al.* (2022).

2.3 **Aprendizado Profundo**

O Aprendizado Profundo (AP) (do inglês, *Deep Learning* (DL)) é uma subárea do *Machine Learning* (ML) e tem como base as redes neurais profundas, que são uma subclasse das Redes Neurais Artificiais (do inglês, *Artificial Neural Networks* (ANNs)). As ANNs são estruturas que agrupam componentes responsáveis por simular o aprendizado dos neurônios humanos, onde cada neurônio artificial é chamado de nó, estes são interconectados em camadas, e cada nó em uma camada se conecta a cada um dos nós da próxima camada (LÓPEZ *et al.*, 2022).

Cada nó da rede, associado a um peso inicialmente aleatório que dita a força de influência de um sobre o outro, realiza operações individuais sobre dados de entrada, como cálculos simples, com a finalidade de extrair atributos e identificar padrões intrínsecos, repassando

os resultados para os nós da próxima camada. No treinamento da rede, esse procedimento é repetido a partir da camada de entrada até a camada de saída, onde é feita a classificação da entrada e comparado esse resultado ao que se esperava obter para ajuste dos pesos através de um algoritmo de retropropagação visando minimizar o erro entre saída obtida e esperada (LÓPEZ *et al.*, 2022).

As ANNs são formadas por três camadas: uma de entrada, uma camada oculta e outra de saída. Redes neurais profundas além das camadas de entrada e saída, possuem várias camadas ocultas e por isso conseguem realizar tarefas mais complexas (LÓPEZ *et al.*, 2022). Alguns tipos de dados que podem ser passados no treinamento de uma rede neural artificial são textos, áudios e imagens (LECUN *et al.*, 2015).

2.3.1 *Redes Neurais Convolucionais*

As redes neurais profundas mais usadas na classificação de imagens são chamadas CNNs (GHOSH *et al.*, 2020). Existem diferentes arquiteturas dessas redes, sendo que todas são compostas por combinações de camadas de convolução, *pooling* e uma camada totalmente conectada (do inglês, *Fully Connected (FC)*), sendo as duas primeiras responsáveis pelas operações principais da rede (LECUN *et al.*, 2015).

2.3.1.1 *Camada de Convolução*

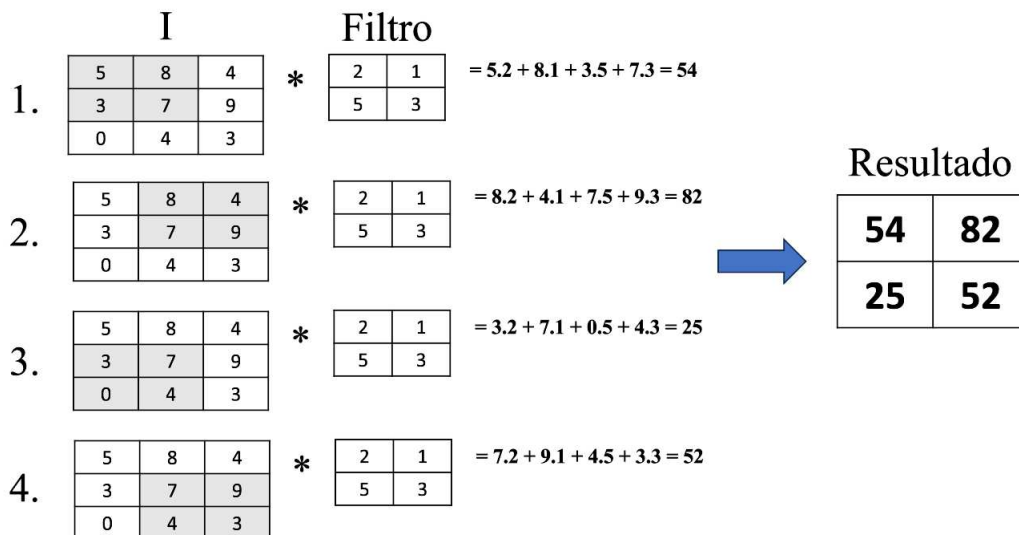
A depender da posição em que se encontra uma camada de convolução na rede, ela pode receber, como entrada, um dado diferente. A primeira camada de convolução, que também é a primeira camada da rede, recebe como entrada a própria imagem, de forma que se essa imagem for colorida sua representação será uma matriz tridimensional composta por altura, largura e canais de cor (comumente vermelho, verde e azul). Por outro lado, se a imagem estiver em escala de cinza, a entrada será uma matriz bidimensional representando sua altura e a largura. Para camadas de convolução subsequentes à primeira, a entrada é um mapa de características, conhecido como *feature map*, que é uma matriz tridimensional representando as características aprendidas nas camadas anteriores (ALZUBAIDI *et al.*, 2021).

Um elemento importante na etapa de convolução é o filtro, conhecido como *kernel*, que é uma pequena matriz de pesos passada sobre a matriz I (que representa a imagem de entrada) ou sobre um mapa de características M . O avanço horizontal e vertical desse *kernel*, é definido pelo passo (ou *stride*), que é o número de posições deslocadas em cada etapa de aplicação. Em

cada etapa da aplicação do *kernel* ocorre o produto escalar entre ele e a parte sobreposta de I ou M e somados todos os produtos envolvidos, de modo que o resultado é um número que representa a resposta do filtro naquela posição, sendo este processo repetido para cada posição possível do filtro em I ou M . Outro conceito presente na etapa de convolução é chamado *padding* que consiste na adição de zeros ou outros valores às bordas da imagem de entrada, com objetivo de manter ou reduzir de forma gradual as dimensões da imagem original após a convolução (DUMOULIN; VISIN, 2018).

Na Figura 12 são ilustradas as etapas de convolução considerando uma matriz $I_{3 \times 3}$ que representa uma imagem de entrada, um filtro 2×2 , *stride* 1, sem a aplicação de *padding*. Em cada etapa é mostrada a parte sobreposta de $I_{3 \times 3}$ representada pelas células sombreadas, os números com correlação entre as células sombreadas e as células do filtro são multiplicados, e, posteriormente são somados os produtos resultantes. Por fim, o valor da soma preenche a célula correspondente no mapa de características. Como essa etapa é uma operação linear, em sua saída é aplicada uma função de ativação para que seja adicionada não linearidade a rede, sendo mais comumente usada a ReLU por proporcionar um treinamento mais rápido que suas equivalentes (RAMACHANDRAN *et al.*, 2017).

Figura 12 – Exemplo de convolução.



Fonte: Elaborado pelo Autor, 2023.

Em alguns casos, é importante calcular a dimensão do mapa de características resultante de uma convolução, conforme a equação

$$W_2 = \frac{(W_1 - F + 2P)}{S} + 1 \quad (2.1)$$

em que W_2 é a largura (ou altura) do mapa de características de saída, W_1 é a largura (ou altura) do mapa de características de entrada (ou imagem de entrada), F é o tamanho do filtro usado na operação de convolução, P é o preenchimento (*padding*), o qual é zero se não existir, e S é o passo (*stride*).

2.3.1.2 Camada de Pooling

Em uma CNN cada camada de *pooling*, geralmente, vem logo após uma camada de convolução, e tem como objetivo simplificar as informações na sua saída. A simplificação é dada pelo fato de que a camada de *pooling* reduz as dimensões dos mapas de características, diminuindo, desse modo, o número de parâmetros a serem aprendidos e a quantidade de computação que a rede precisa realizar. Assim como na etapa de convolução, na etapa de *pooling* existem os conceitos de filtro, *stride* e *padding*, desempenhando funções similares, pois a única exceção é com relação ao filtro que unicamente precisa ter um tamanho definido que irá ser determinante na taxa de redução da dimensionalidade do mapa de características (YAMASHITA *et al.*, 2018).

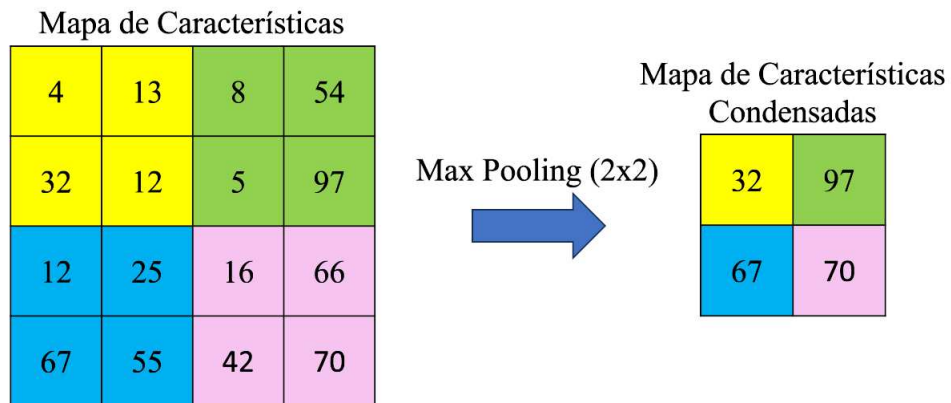
A operação de *pooling* envolve deslizar um filtro bidimensional sobre cada canal do mapa de características de acordo com o *stride* definido e resumir as características localizadas dentro da região coberta pelo filtro.

Os tipos mais comuns de *pooling* são o *MaxPooling* e o *AveragePooling*. O *MaxPooling* seleciona o elemento máximo de uma região do mapa de características coberta pelo filtro, resultando em um mapa de características composto pelos atributos mais proeminentes do mapa anterior (ALZUBAIDI *et al.*, 2021). O *AveragePooling* calcula a média dos elementos presentes na região do mapa de características coberta pelo filtro, o que resulta em um novo mapa contendo a média dos recursos presentes no mapa anterior.

Na Figura 13 é representada a operação de *pooling* usando *MaxPooling*, cujo tamanho do filtro é 2×2 , *stride* 2, e sem *padding*. Cada região 2×2 do mapa de características é colorida com a cor correspondente da célula de resultado do mapa de características condensadas. A região 2×2 amarela tem os valores 4, 13, 32 e 12, então, pela operação de *MaxPooling*, é escolhido o 32 por ser o maior. Este é colocado na célula amarela do mapa resultante que corresponde a essa região. O mesmo procedimento é feito para as demais regiões até ser formado o mapa de

características condensadas.

Figura 13 – Exemplo de *MaxPooling*.



Fonte: Elaborado pelo Autor, 2023.


Assim como na operação de convolução, na operação de *pooling*, é desejável calcular as dimensões do mapa de características resultante e para isso a equação 2.1 também é utilizada considerando os mesmos termos da operação de convolução.

3 METODOLOGIA

3.1 Base de Imagens

A base de imagens de (BUERHOP-LUTZ *et al.*, 2018; DEITSCH *et al.*, 2019)¹ composta por 2624 imagens de células FVs de $Si - m$ e $Si - p$, com 300 x 300 pixels de resolução, obtidas de 44 módulos FVs. Uma amostra com 1074 imagens de células de $Si - m$ foi usada no presente trabalho, elas estão normalizadas em contraste e perspectiva, e rotuladas em funcionais e defeituosas, com vários graus de degradação. Nas Figuras 14(a) e 14(b), tem-se imagens de EL de células FVs não defeituosas e nas Figuras 14(c) e 14(d) defeituosas, com trincas e áreas sombreadas respectivamente.

Figura 14 – Células de Si (a) e (b) Condições normais de funcionamento. (c) Defeito ocasionado por trincas. (d) Elevado grau de sombreamento.



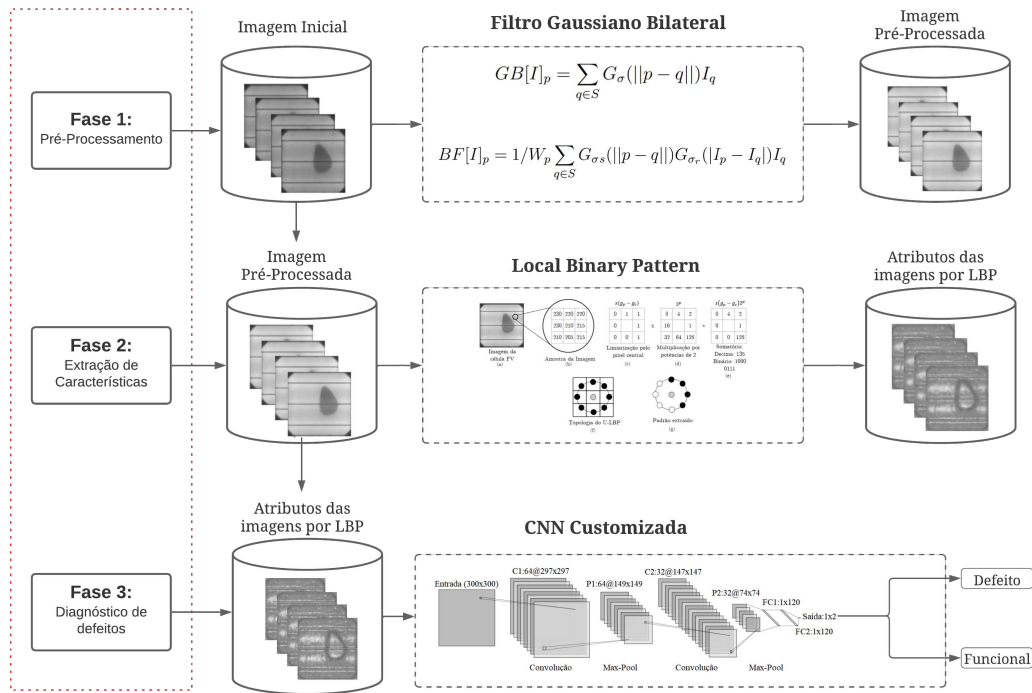
Fonte: Elaborado pelo Autor, 2023.

3.2 Modelo Proposto

O esquemático do modelo proposto está ilustrado na Figura 15. Nas Fases 1 e 2 ocorre o pré-processamento e extração de características das imagens, onde os defeitos das células nas imagens de EL são aprimorados e realçados através da aplicação do filtro Gaussiano Bilateral e pelo extrator de texturas LBP. Na Fase 3 as imagens resultantes da aplicação do LBP são repassadas para as etapas de treino e teste da CNN customizada. É nessa última etapa que ocorre o refinamento da extração de características e a classificação das células FVs em defeituosas ou não defeituosas.

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

Figura 15 – Modelo para detecção de defeitos em células FVs a partir de imagens de EL.



Fonte: Elaborado pelo Autor, 2023.

3.2.1 Filtro Gaussiano Bilateral

A ideia de que as informações nas bordas auxiliam na identificação de defeitos presentes nas células FVs através das imagens de EL, justifica a escolha do filtro Gaussiano Bilateral para a etapa de pré-processamento, pois este filtra os ruídos, suavizando áreas homogêneas, preservando as informações das bordas (GARG, 2020). A equação associada ao filtro de desfoque Gaussiano é dada por

$$GB[I]_p = \sum_{q \in S} G_{\sigma}(\|p - q\|)I_q, \quad (3.1)$$


sendo que $GB[I]_p$ é a saída do filtro do pixel p após o desfoque. O lado direito de (3.1) representa o somatório de todos os pixels I_q com $q \in S$ pela função Gaussiana $G_{(\sigma)}$, p e q são os vetores que representam as coordenadas espaciais dos pontos na imagem e $\|p - q\|$ representa a diferença absoluta entre as intensidades dos pixels I_p e I_q . Já o filtro Gaussiano Bilateral é dado por

$$BF[I]_p = 1/W_p \sum_{q \in S} G_{\sigma_s}(\|p - q\|)G_{\sigma_r}(\|I_p - I_q\|)I_q \quad (3.2)$$

em que $1/W_p$ é o fator de normalização, σ_s e σ_r são parâmetros que determinam o grau de borrramento e de preservação das bordas, respectivamente.

Foram adotados no modelo os parâmetros $1/W_p = 1/255$ e $\sigma_s = \sigma_r = 15$. Esses valores permitem normalizar a intensidade dos pixels (I_p) para que $I_p \in \{x \in \mathbb{R} \mid 0 \leq x \leq 1\}$ sem introduzir alterações significativas no brilho das imagens. A Figura 16 apresenta o resultado da aplicação do filtro Gaussiano Bilateral em uma célula FV de $Si - m$. A aplicação do filtro realiza uma suavização que preserva as bordas, levando em consideração as diferenças de intensidade entre os pixels. Isso resulta em uma imagem suavizada, mas com bordas nítidas e preservação de detalhes.

Figura 16 – (a) Imagem original. (b) Imagem em níveis de cinza. (c) Resultado da aplicação do filtro Gaussiano Bilateral.



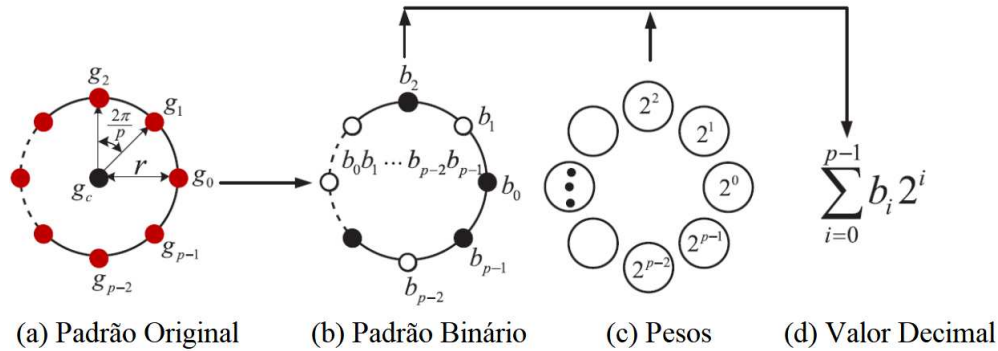
Fonte: Elaborado pelo Autor, 2023.

3.2.2 Extrator de texturas LBP

LBP (OJALA *et al.*, 1994) é uma técnica de extração de atributos de textura invariante em escala de cinzas que opera em cada pixel da imagem para gerar uma nova imagem de padrões binários locais. Essa técnica rotula os pixels vizinhos de acordo com a relação estabelecida entre suas intensidades e a de um pixel central.

Na Figura 17(a), os P pixels da vizinhança, são identificados por $g_p(x_p, y_p)$, em uma região da imagem com circunferência r , onde $p = \{0, \dots, P - 1\}$, e o pixel central $g_c = (0, 0)$, sendo o posicionamento de cada pixel da vizinhança (x_p, y_p) , para $x_p = -R \sin(2\pi p/P)$ e $y_p = R \cos(2\pi p/P)$. O valor de R determina a distância entre o pixel central e os pixels vizinhos que serão considerados na computação do LBP. Assim, tem-se que

Figura 17 – Método da extração de atributos LBP.



Fonte: Elaborado pelo Autor, 2023.

$$LBP_{(P,R)} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, \quad (3.3)$$


$$s(g_p - g_c) = \begin{cases} 1 & \text{se } g_p - g_c \geq 0 \\ 0 & \text{caso contrário.} \end{cases}$$

Na Figura 17(b) é ilustrada a etapa subsequente à comparação dos pixels da vizinhança com o pixel central. Na Figura 17(c) a associação de cada posição dos bits com os pesos, em potência de 2, sobre a região circular e na Figura 17(d) a representação matemática do valor decimal gerado.

Variantes mais robustas do LBP, como o LBP Uniforme (do inglês, U-LBP) (HAQ *et al.*, 2017), LBP Invariante à Rotação (do inglês, *Invariant to Rotation-Local Binary Pattern* (IR-LBP)) (MOORE; BOWDEN, 2011) e LBP Uniforme e Invariante à Rotação (do inglês, *Uniform and Invariant to Rotation-Local Binary Pattern* (UIR-LBP)) (WANG *et al.*, 2014) são encontradas na literatura. Considerando as características de uniformidade de textura do conjunto de dados, realizamos os nossos experimentos com o método U-LBP.

Na primeira linha da Figura 18 estão exemplos de imagens de EL de células FVs, com os destaques vermelhos nos defeitos de microtrincas, imperceptíveis a um especialista em uma primeira análise. Na segunda linha temos as imagens resultantes da aplicação do U-LBP às primeiras, nas quais observa-se o realce que a técnica produziu aos defeitos de microtrincas. Além das microtrincas, a aplicação do U-LBP evidencia os defeitos de trincas visíveis e de manchas escuras ocasionadas por pontos quentes.

Figura 18 – Imagens de células FVs e o resultado da aplicação do U-LBP.




Fonte: Elaborado pelo Autor, 2023.

3.2.3 CNN Customizada

Em geral, uma CNN é composta por três tipos de camadas de processamento: convolução (*C*), *pooling* (*P*) e totalmente conectadas (*FC*). As duas primeiras realizam a extração de características das imagens e a última mapeia os recursos extraídos para classificação. É apresentada na Figura 19 a representação da CCNN. Sua entrada recebe os atributos de textura produzidos pelo método LBP. A topologia proposta é formada por duas camadas de convolução *C1* e *C2*, duas de *pooling* *P1* e *P2*, e duas totalmente conectadas *FC1* e *FC2*. A notação ($n@p \times p$) na Figura 19 indica o número de filtros para as camadas de convolução e *pooling* e o número de neurônios para as camadas *FC1* e *FC2*, bem como as dimensões das imagens produzidas em cada camada.

Figura 19 – Topologia da Rede Neural Convolutiva Customizada.



Fonte: Elaborado pelo Autor, 2023.

3.3 Metodologia de avaliação

O desempenho do modelo foi avaliado por validação cruzada, onde as 1074 imagens foram divididas, aleatoriamente, em grupos de teste e treino (20% e 80%). A CNN Customizada foi treinada com o otimizador *Adaptive Moment Estimation (Adam)*, função custo *Cross-Entropy Loss*, tamanho do conjunto de treino por época $bs = 10$, número de épocas $N_e = 50$, taxa de aprendizagem $\eta = 0,01$ e fator de regularização de pesos $\lambda = 0,0001$.

A partir dos dados de teste, as métricas de avaliação Acurácia (A_c), Sensibilidade (S_e) e Especificidade (E_s) foram calculadas através das equações:

$$A_c = \frac{VP + VN}{VP + FP + VN + FN}, \quad (3.4)$$

$$S_e = \frac{VP}{VP + FN}, \quad (3.5)$$

e

$$E_s = \frac{VN}{VN + FP}. \quad (3.6)$$

Nessas equações, VP é o total de células FVs classificadas corretamente como defeituosas, VN o total daquelas classificadas corretamente como não defeituosas, FP as classificadas defeituosas sendo não defeituosas e FN as classificadas não defeituosas sendo defeituosas.

4 RESULTADOS E DISCUSSÕES

Na Tabela 1 observa-se a matriz de confusão resultante da validação cruzada do modelo computacional. Esse modelo classificou corretamente 86 células FVs como não defeituosas e 104 como defeituosas. Porém, esse classificou incorretamente 6 células FVs defeituosas como não defeituosas (erro tipo 1) e 20 não defeituosas como defeituosas (erro tipo 2). Logo, tem-se que $A_c = 88\%$, $S_e = 94\%$ e $E_s = 81\%$. O modelo mostrou-se mais eficiente em detectar células FVs defeituosas do que não defeituosas, pois $S_e > E_s$, sendo adequado ao problema em questão, que é mais tolerante a erros do tipo 2 do que do tipo 1.

Tabela 1 – Matriz de confusão das predições realizadas pelo modelo.

	Valor Predito	
	Defeito	Sem Defeito
Defeito	104	20
Sem Defeito	6	86

A Tabela 2 mostra os resultados de acurácia dos modelos que outros autores propuseram, e que também empregam CNNs em sua implementação. Akram *et al.* (2019) obtiveram, com as redes convolucionais VGG16 e VGG11, o melhor desempenho ($A_c = 93\%$). Os demais resultados, como os da InceptionV3 ($A_c = 88\%$), VGG16 ($A_c = 88\%$) e VGG19 (DEITSCH *et al.*, 2019) ($A_c = 88\%$), são compatíveis ao que foi reportado no presente trabalho ($A_c = 88\%$). Apesar de ter menos parâmetros que os demais modelos, a CNN Customizada mostra-se competitiva, em termos de acurácia, com as demais redes, com menor complexidade e menor custo computacional para o treinamento da rede.

Tabela 2 – Resultado do modelo proposto e de outros trabalhos.

Autores	Algoritmo proposto	Total de parâmetros	Acurácia(%)
(DEITSCH <i>et al.</i> , 2019)	SVM	-	84
	VGG19	140.10 ⁶	88
(ROCHA <i>et al.</i> , 2023)	RF	-	90
	SVM	-	87
	Naive Bayes (NB)	-	85
	<i>k</i> -Nearest Neighbors (k-NN)	-	84
(AKRAM <i>et al.</i> , 2019)	VGG11	130.10 ⁶	93
Outras topologias	InceptionV3	24.10 ⁶	88
	VGG16	120.10 ⁶	88
Modelo Proposto	CNN Customizada	21.10 ⁶	88

5 CONCLUSÕES E TRABALHOS FUTUROS

O presente trabalho propôs um modelo para detecção de defeitos em células FVs de $Si - m$ a partir de imagens de EL. Foi demonstrado que o pré-processamento das imagens com o Filtro Bilateral Gaussiano e o método LBP realça os defeitos das células FVs nas imagens. A CNN Customizada tem baixa complexidade, em termos de número de parâmetros, comparado com topologias tradicionais de CNN, mas sem comprometer o desempenho na classificação de defeitos em células FVs. O modelo proposto como um todo mostrou-se competitivo, em termos de acurácia, com os trabalhos levantados da literatura. O mesmo mostrou-se adequado ao problema de detecção de defeitos em células FVs por apresentar menor erro para detectar as células defeituosas do que as não defeituosas.

5.1 Trabalhos Futuros

Algumas melhorias que podem ser feitas a partir deste trabalho e implementadas em trabalhos futuros, são:

- Utilizar imagens de células FVs $Si - p$ e outros tipos de células além de $Si - m$.
- Aplicar técnicas de aumento de dados para generalizar mais a rede neural.
- Explorar outros tipos de extratores de textura além do LBP.
- Implementar uma abordagem multiclasse para inferir diferentes níveis de degradação das células e também os tipos de falhas presentes.
- Explorar diferentes topologias de CNNs.

REFERÊNCIAS

- ABDALLAH, F. S. M.; ABDULLAH, M.; MUSIRIN, I.; ELSHAMY, A. M. Intelligent solar panel monitoring system and shading detection using artificial neural networks. **Energy Reports**, v. 9, p. 324–334, 2023. ISSN 2352-4847. 2022 The 3rd International Conference on Power and Electrical Engineering. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484723009150>>.
- ACIKGOZ, H.; KORKMAZ, D.; BUDAK, U. Photovoltaic cell defect classification based on integration of residual-inception network and spatial pyramid pooling in electroluminescence images. **Expert Systems with Applications**, v. 229, p. 120546, 2023. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417423010485>>.
- 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.
- 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.; SANTAMARIA J. FADHEL, M. A.; AL-AMIDIE, M.; FARHAN, L.; AL, e. Review of deep learning: Concepts, cnn architectures, challenges, applications, future directions. **Journal of Big Data**, v. 8, 2021.
- ANJOS, R. S. dos. **Análise e simulação de pontos quentes em painéis fotovoltaicos**. 2016. Disponível em: <<https://repositorio.ipl.pt/bitstream/10400.21/6746/1/Disserta%20c3%a7%20a30.pdf>>.
- BAKIR, H.; KUZHIPALLIL, F. A.; MERABET, A. Automatic detection of deteriorated photovoltaic modules using irt images and deep learning (cnn, lstm) strategies. **Engineering Failure Analysis**, v. 146, p. 107132, 2023. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630723000869>>.
- BLOG, E. F. **Energia fotovoltaica es una fuente de energía renovable**. 2018. <<https://nergiasfotovoltaicasblog.blogspot.com/2018/05/energia-fotovoltaica-es-una-fuente-de.html>>.
- 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.
- CAO, Y.; PANG, D.; YAN, Y.; JIANG, Y.; TIAN, C. A photovoltaic surface defect detection method for building based on deep learning. **Journal of Building Engineering**, v. 70, p. 106375, 2023. ISSN 2352-7102. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352710223005545>>.
- 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**, Elsevier BV, v. 185, p. 455–468, jun. 2019. ISSN 0038-092X.

DHIMISH, M.; HOLMES, V.; MEHRDADI, B.; DALES, M. The impact of cracks on photovoltaic power performance. **Journal of Science: Advanced Materials and Devices**, v. 2, n. 2, p. 199–209, 2017. ISSN 2468-2179. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2468217917300540>>.

DHIMISH, M.; HU, Y. Rapid testing on the effect of cracks on solar cells output power performance and thermal operation. **Scientific Reports**, v. 12, 2022. ISSN 2045-2322. Disponível em: <<https://link.springer.com/article/10.1038/s41598-022-16546-z>>.

DJORDJEVIC, S.; PARLEVLJET, D.; JENNINGS; PHILIB. Detectable faults on recently installed solar modules in western australia. **Renewable Energy**, v. 67, p. 215–221, 2014.

DOLARA, A.; LAZAROIU, G. C.; LEVA, S.; MANZOLINI, G.; VOTTA, L. Snail trails and cell microcrack impact on pv module maximum power and energy production. **IEEE Journal of Photovoltaics**, v. 6, n. 5, p. 1269–1277, 2016.

DUMOULIN, V.; VISIN, F. **A guide to convolution arithmetic for deep learning**. 2018.

ECOFLOW. **Solar Photovoltaic vs Solar Thermal**. 2023. <<https://blog.ecoflow.com/us/solar-photovoltaic-vs-solar-thermal/>>. Acessado em: 06 agosto 2023.

ELETRONICAONLINE. **Aplicaciones de los Diodos**. 2023. Disponível em: <<https://electronicaonline.net/componentes-electronicos/diodo/aplicaciones-de-los-diodos/>>.

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>>.

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.

GARG, B. Restoration of highly salt-and-pepper-noise-corrupted images using novel adaptive trimmed median filter. **Signal, Image and Video Processing**, v. 14, n. 8, p. 1555–1563, 2020.

GHOSH, A.; SUFIAN, A.; SULTANA, F.; CHAKRABARTI, A.; DE, D. Fundamental concepts of convolutional neural network. In: _____. [S.l.: s.n.], 2020. p. 519–567. ISBN 978-3-030-32643-2.

GHOSH, S.; SINGH, S. K.; YADAV, V. K. Experimental investigation of hotspot phenomenon in pv arrays under mismatch conditions. **Solar Energy**, v. 253, p. 219–230, 2023. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X23001147>>.

HAQ, E. U.; HUARONG, X.; KHATTAK, M. I. Notice of retraction: Face recognition by svm using local binary patterns. In: **2017 14th Web Information Systems and Applications Conference (WISA)**. [S.l.: s.n.], 2017. p. 172–175.

HASSAN, S.; DHIMISH, M. Enhancing solar photovoltaic modules quality assurance through convolutional neural network-aided automated defect detection. **Renewable Energy**, v. 219, p. 119389, 2023. ISSN 0960-1481. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960148123013046>>.

IEA. **Participação da capacidade de energia acumulada por tecnologia, 2010-2027**. 2022. <<https://www.iea.org/data-and-statistics/charts/share-of-cumulative-power-capacity-by-technology-2010-2027>>. Acessado em: 08 agosto 2023 Licença: CC BY 4.0.

IEA. **Solar PV**. 2022. <<https://www.iea.org/energy-system/renewables/solar-pv#tracking>>. Acessado em: 08 agosto 2023.

IRENA. **Renewable capacity statistics 2023**. [S.l.], 2023.

JIN, J.; XIN, J.; SABOOR, A. New model to analyze the profit and cost of large commercial by considering solar energy. **International Journal of Hydrogen Energy**, 2023. ISSN 0360-3199. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360319923045044>>.

KIM, D.; YOUN, J.; KIM, C. Automatic fault recognition of photovoltaic modules based on statistical analysis of uav thermography. **ISPRS, XLII-2/W6**, p. 179–182, 2017.

KORKMAZ, D.; ACIKGOZ, H. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. **Engineering Applications of Artificial Intelligence**, v. 113, p. 104959, 2022. ISSN 0952-1976. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197622001695>>.

KREFT, W.; PRZENZAK, E.; FILIPOWICZ, M. Photovoltaic chain operation analysis in condition of partial shading for systems with and without bypass diodes. **Optik**, v. 247, p. 167840, 2021. ISSN 0030-4026. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0030402621014236>>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, 2015.

LÓPEZ, O. A. M.; LÓPEZ, A. M.; CROSSA, J. Fundamentals of artificial neural networks and deep learning. In: _____. **Multivariate Statistical Machine Learning Methods for Genomic Prediction**. Cham: Springer International Publishing, 2022. p. 379–425. ISBN 978-3-030-89010-0. Disponível em: <https://doi.org/10.1007/978-3-030-89010-0_10>.

MILES, R.; HYNES, K.; FORBES, I. Photovoltaic solar cells: An overview of state-of-the-art cell development and environmental issues. **Progress in Crystal Growth and Characterization of Materials**, v. 51, n. 1, p. 1–42, 2005. ISSN 0960-8974. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0960897405000410>>.

MOORE, S.; BOWDEN, R. Local binary patterns for multi-view facial expression recognition. **Computer Vision and Image Understanding**, v. 115, n. 4, p. 541–558, 2011.

Munawer Al-Otum, H. Deep learning-based automated defect classification in electroluminescence images of solar panels. **Advanced Engineering Informatics**, v. 58, p. 102147, 2023. ISSN 1474-0346. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1474034623002756>>.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. In: **Proceedings of 12th International Conference on Pattern Recognition**. [S.l.: s.n.], 1994. v. 1, p. 582–585.

POURASL, H. H.; BARENJI, R. V.; KHOJASTEHEZHAD, V. M. Solar energy status in the world: A comprehensive review. **Energy Reports**, v. 10, p. 3474–3493, 2023. ISSN 2352-4847. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484723014579>>.

- PURANIK, V. E.; GUPTA, R. Analysis and insight of electroluminescence imaging in the assessment of potential-induced degradation in crystalline silicon photovoltaic module. **Engineering Failure Analysis**, v. 134, p. 106027, 2022. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630722000012>>.
- RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. **Searching for Activation Functions**. 2017.
- ROCHA, A. M. da; SOUZA, M. M. S. de; SERAFIM, F. L.; FERNANDES, C. A. R.; VIANA Ícaro B. Análise de defeitos em células fotovoltaicas através da matriz de coocorrência de níveis de cinza. **XVI Simpósio Brasileiro de Automação Inteligente (SBAI)**, 2023.
- SIMONYAN; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: **3rd International Conference On Learning Representations (ICLR 2015)**. [S.l.]: Computational and Biological Learning Society, 2015. v. 1, p. 1–14.
- SOHAIL, A.; Ul Islam, N.; Ul Haq, A.; Ul Islam, S.; SHAFI, I.; PARK, J. Fault detection and computation of power in pv cells under faulty conditions using deep-learning. **Energy Reports**, v. 9, p. 4325–4336, 2023. ISSN 2352-4847. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352484723003311>>.
- SOLAR, B. **Analysis of Hot Spots in Crystalline Silicon Modules and their Impact on Roof Structures**. 2011. Disponível em: <https://www1.eere.energy.gov/solar/pdfs/pvmrw2011_29_csi_cunningham.pdf>.
- SZEGEDY, C.; IOFFE, S.; VANHOUCKE, V.; ALEMI, A. A. Inception-v4, inception-resnet and the impact of residual connections on learning. **ArXiv**, abs/1602.07261, 2016.
- 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. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X20302875>>.
- WANG, Y.; ZHAO, Y.; CHEN, Y. Texture classification using rotation invariant models on integrated local binary pattern and zernike moments. **EURASIP Journal on Advances in Signal Processing**, v. 2014, n. 1, p. 182, 2014.
- Waqar Akram, M.; LI, G.; JIN, Y.; ZHU, C.; JAVAID, A.; Zuhaib Akram, M.; Usman Khan, M. Study of manufacturing and hotspot formation in cut cell and full cell pv modules. **Solar Energy**, v. 203, p. 247–259, 2020. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X20304370>>.
- XIE, X.; LAI, G.; YOU, M.; LIANG, J.; LENG, B. Effective transfer learning of defect detection for photovoltaic module cells in electroluminescence images. **Solar Energy**, v. 250, p. 312–323, 2023. ISSN 0038-092X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0038092X22007940>>.
- YAMASHITA, R.; NISHIO, M.; DO, R.; TOGASHI, K. Convolutional neural networks: an overview and application in radiology. **Insights into Imaging**, v. 9, 2018.
- ZHAO, X.; SONG, C.; ZHANG, H.; SUN, X.; ZHAO, J. Hnet-based automatic identification of photovoltaic module defects using electroluminescence images. **Energy**, v. 267, p. 126605, 2023. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544222034922>>.