Método computacional para automação na detecção de defeitos em células fotovoltaicas utilizando imagens em eletroluminescência

Alan M. da Rocha * **Marcelo M. S. de Souza** *
Carlos A. R. Fernandes * **Lucas P. Valente** *

* *Programa de Pós-Graduação em Engenharia Elétrica e Computação (PPGEEC), Campus Sobral, Universidade Federal do Ceará, CE, Brasil (e-mail: eng.alanmarquesrocha@gmail.com, marcelo@ufc.br, alexandrefernandes@ufc.br, lucaspedrosaval@alu.ufc.br).*

Abstract: The generation of photovoltaic (PV) energy has been widely adopted on a global scale due to its clean nature and affordable cost. A crucial issue in PV generation systems is the integrity of PVs cells, which often operate under challenging environmental conditions such as wind, rain, salinity, and dust. Thus, there is a growing demand for technologies aimed at improving the efficiency and reliability of these systems, especially through the automation of the defect detection process in PV cells. In this context, a computational model has been proposed to distinguish defective monocrystalline silicon PV cells based on texture attributes extracted from electroluminescent (EL) images. Additionally, the model incorporates a Custom Convolutional Neural Network (CNN), which features a reduced number of parameters compared to other conventional neural network topologies. The model's performance was evaluated through cross-validation using a widely recognized dataset of PV cell images in the literature. The parameter reduction implemented in the Custom CNN did not compromise the model's performance, demonstrating consistent results with those reported in the literature. Therefore, the proposed model is a viable solution to the problem of defect detection in PV cells, capable of correctly identifying 94% of defective cells and 91% of non-defective ones.

Resumo: A geração de energia fotovoltaica (FV) tem sido amplamente adotada em escala global devido à sua natureza limpa e custo acessível. Uma questão crucial nos sistemas de geração FV é a integridade das células FVs, que frequentemente operam sob condições ambientais desafiadoras, como vento, chuva, salinidade e poeira. Assim, existe uma demanda crescente por tecnologias que visem melhorar a eficiência e a confiabilidade desses sistemas, especialmente através da automatização do processo de detecção de defeitos em células FVs. Neste contexto, foi proposto um modelo computacional que visa distinguir células FVs de silício monocristalino defeituosas com base em atributos de textura extraídos de imagens eletroluminescentes (EL). Além disso, o modelo incorpora uma Rede Neural Convolucional (CNN) Customizada, a qual apresenta um número reduzido de parâmetros em comparação com outras topologias de redes neurais convencionais. O desempenho do modelo foi avaliado por meio de validação cruzada utilizando uma base de imagens de células FVs amplamente reconhecida na literatura. A redução de parâmetros implementada na CNN Customizada não comprometeu o desempenho do modelo, demonstrando resultados consistentes com os relatados na literatura. Portanto, o modelo proposto é uma solução viável para o problema de detecção de defeitos em células FVs, sendo capaz de identificar corretamente 94% das células defeituosas e 91% das não defeituosas.

Keywords: Fault Detection; Photovoltaic Cell; Convolutional Neural Network; Local Binary Pattern.

Palavras-chaves: Detecção de Falhas; Célula Fotovoltaica; Rede Neural Convolucional; Padrão Binário Local.

1. INTRODUÇÃO

A instalação de sistemas de geração de energia elétrica solar fotovoltaica (FV) cresceu mundialmente na última década, sendo que parte desses sistemas não recebe manutenção preventiva. Desta forma, esses ficam suscetíveis a falhas elétricas, com custos de reparação elevados e impactantes aos consumidores. A célula FV é o componente que mais se degrada nesses sistemas devido a sua exposição a condições ambientais adversas, como vento, chuva, salinidade e poeira (Chaudhary and Chaturvedi, 2018). Logo, a melhoria da eficiência e confiabilidade dos sistemas de geração FVs dependem do desenvolvimento de tecnologias que automatizem os processos de inspeção, detecção e manutenção de defeitos em suas células.

Um método amplamente utilizado para este propósito é a inspeção de imagens eletroluminescentes (EL) (Deitsch et al., 2019). Essas últimas são produzidas por câmeras sensíveis ao comprimento de onda dos fótons emitidos pelas células FVs quando estimuladas por uma fonte de tensão contínua. Como resultado, as partes defeituosas das células apresentam-se nas imagens com tons mais escuros (Fan et al., 2022).

O artigo apresenta um modelo computacional proposto para a discriminação de células FVs de silício monocristalino (*Si-m*) defeituosas com base em imagens EL. O método proposto se fundamenta na extração de atributos de textura das imagens utilizando o Padrão Binário Local, do inglês *Local Binary Pattern* (LBP) e na subsequente classificação das células FVs como funcionais ou defeituosas por meio de uma Rede Neural Convolucional, do inglês *Convolutional Neural Network* (CNN). Além do modelo em questão, destaca-se uma contribuição adicional na forma de uma topologia de rede convolucional, denominada CNN Customizada, que demonstrou ser mais competitiva em termos de desempenho e complexidade do que as topologias de rede convencionalmente utilizadas, como a VGG (Simonyan and Zisserman, 2015), a Inception e ResNet (Szegedy et al., 2016), em problemas de identificação de defeitos em células FVs.

Neste artigo, as seções são organizadas da seguinte forma: na Seção 2, são apresentados os trabalhos relacionados ao tema; na Seção 3, é detalhada a base de imagens utilizada para validar o modelo proposto; na Seção 4, descreve-se o modelo computacional, incluindo seus três componentes: o filtro de pré-processamento, o método de extração de atributos de textura LBP e a CNN Customizada; na Seção 5, é discutida a metodologia de avaliação do modelo; na Seção 6, são analisados os resultados obtidos; e na Seção 7, são apresentadas as conclusões derivadas do trabalho realizado.

2. TRABALHOS RELACIONADOS

Trabalhos recentes propuseram modelos para detecção e identificação de defeitos em células FVs por imagens EL. Fan et al. (2022) apresentaram um modelo especializado para detecção de defeitos de microtrincas em células FVs de silicio policristalino (*Si-p*). Esse modelo, baseado em redes convolucionais, fusão de atributos e transferência de aprendizado, alcançou acurácia de $99,11\%$. Tang et al. (2022) sugeriram um detector de linhas multiescala em conjunto com a matriz Hessiana para o pré-processamento das imagens antes da extração de atributos por uma rede CNN. Essa proposta realça os defeitos de trincas em imagens ELs ruidosas de células FVs de silício policristalino, melhorando a qualidade dos atributos obtidos pela CNN. Como resultado, obtiveram uma acurácia de 93%.

Tang et al. (2020) ensaiaram redes convolucionais das topologias VGG16, ResNet50, InceptionV3 e MobileNet, e empregaram uma rede generativa adversária para aumentar o número de imagens para treinamento. O melhor resultado que os autores obtiveram em termos de acurácia foi de 83%. Deitsch et al. (2019) propuseram um modelo com um classificador Máquina de Vetor de Suporte, do inglês *Support Vector Machine* (SVM) e uma CNN da topologia VGG19. Eles realizaram experimentos com as imagens da base de dados disponibilizada por Buerhop-Lutz et al. (2018), obtendo acurácia de 82%. Akram et al. (2019) sugeriram um modelo com a topologia VGG11, realizando experimentos com a mesma base de Buerhop-Lutz et al. (2018), obtendo acurácia de 93%.

3. BASE DE IMAGENS

A base de imagens de Buerhop-Lutz et al. (2018); Deitsch et al. (2019) [1] contém 1074 amostras de imagens de células FVs de silício monocristalino, com 300 x 300 pixels de resolução, obtidas de 44 módulos FVs. Essas imagens estão normalizadas em contraste, perspectiva, e rotuladas em funcionais e defeituosas, com vários graus de degradação. Nas Figuras 1(a) e 1(b), são apresentadas imagens EL de células FVs não defeituosas e nas Figuras 1(c) e 1(d) defeituosas, com trincas e áreas sombreadas respectivamente.

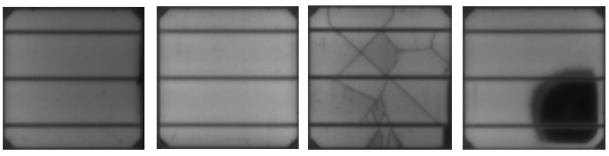

Figura 1. Células de *Si-m* (a) e (b) Condições normais de funcionamento. (c) Defeito ocasionado por trincas. (d) Elevado grau de sombreamento.

4. MODELO PROPOSTO

O modelo computacional proposto é ilustrado na Figura 2. As etapas de Pré-Processamento e de Extração de Características (Fases 1 e 2) são responsáveis por aprimorar e realçar as características dos defeitos nas imagens EL brutas, por meio da aplicação do filtro Gaussiano Bilateral e do extrator de texturas LBP. Este último produz a representação das texturas codificadas como imagens, as quais alimentam o treinamento e teste da CNN Customizada (Fase 3). Além de refinar a extração de características, esta última fase classifica as células FVs como defeituosas ou não defeituosas.

[1] https://github.com/zae-bayern/elpv-dataset

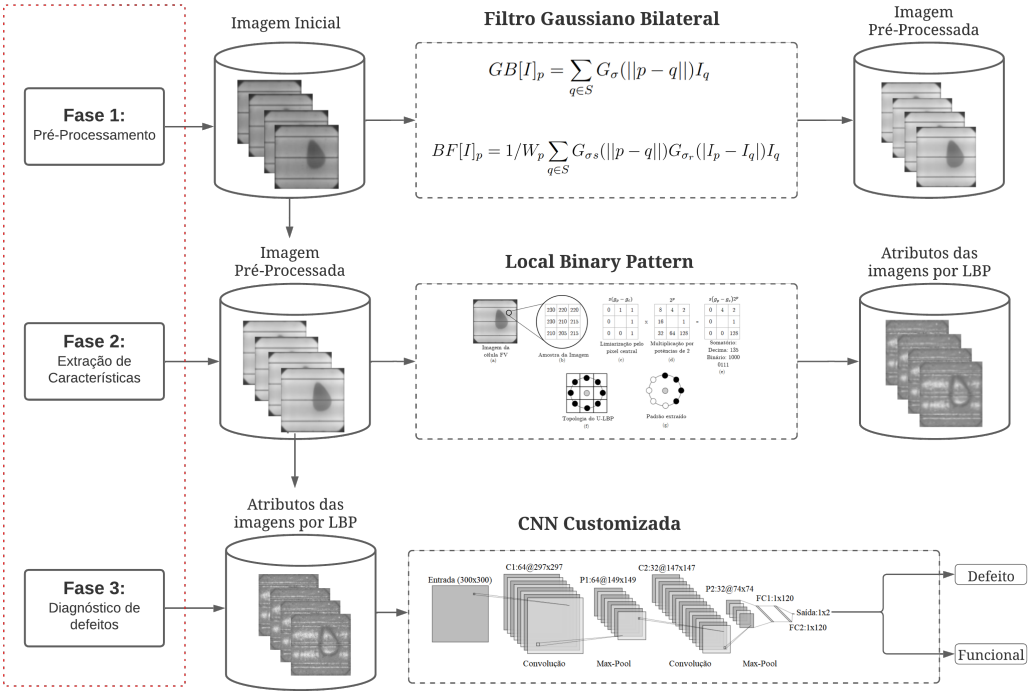

Figura 2. Modelo para detecção de defeitos em células fotovoltaicas a partir de imagens de eletroluminescência.

4.1 Filtro Gaussiano Bilateral

As informações presentes nas bordas são pistas importantes para identificação dos defeitos presentes nas células FVs a partir das imagens EL. Desta forma, escolhemos o filtro Gaussiano Bilateral para pré-processamento, pois este filtra ruídos, suavizando áreas homogêneas, preservando as informações das bordas (Garg, 2020). O filtro de desfoque Gaussiano é definido pela Equação (1)

$$GB[I]_{\mathbf{p}} = \sum_{\mathbf{q} \in S} G_\sigma(||\mathbf{p} - \mathbf{q}||)I_{\mathbf{q}}, \tag{1}$$

em que $GB[I]_{\mathbf{p}}$ é a saída do filtro do pixel p após o desfoque. O lado direito da Equação (1) representa o somatório de todos os pixels $I_{\mathbf{q}}$ com $\mathbf{q} \in S$ pela função Gaussiana $G_{(\sigma)}$, S representa o conjunto de pontos ao redor do ponto central $\mathbf{p}$ que são considerados na operação de desfoque, $\mathbf{p}$ e $\mathbf{q}$ são os vetores que representam as coordenadas espaciais dos pontos na imagem e $||\mathbf{p} - \mathbf{q}||$ representa a diferença absoluta entre as intensidades dos pixels $I_{\mathbf{p}}$ e $I_{\mathbf{q}}$.

Já o filtro Gaussiano Bilateral é dado pela Equação (2)

$$BF[I]_{\mathbf{p}} = 1/W_{\mathbf{p}} \sum_{\mathbf{q} \in S} G_{\sigma_s}(||\mathbf{p} - \mathbf{q}||)G_{\sigma_r}(|I_{\mathbf{p}} - I_{\mathbf{q}}|)I_{\mathbf{q}} \tag{2}$$

em que $1/W_{\mathbf{p}}$ é o fator de normalização e σ_s e σ_r são parâmetros que determinam o grau de borramento e de preservação das bordas, respectivamente.

No método em questão, foram adotados os parâmetros $1/W_{\mathbf{p}} = 1/255$ e $\sigma_s = \sigma_r = 15$. Esses valores permitem normalizar a intensidade dos pixels ($I_{\mathbf{p}}$) para que $I_{\mathbf{p}} \in \{x \in \mathbb{R} \mid 0 \leq x \leq 1\}$ sem introduzir alterações significativas no brilho das imagens. A Figura 3 apresenta um 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.

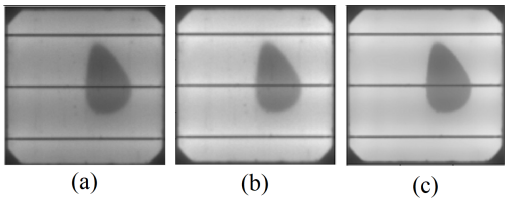

Figura 3. (a) Imagem original. (b) Imagem em níveis de cinza. (c) Resultado da aplicação do filtro Gaussiano Bilateral.

4.2 Extrator de texturas LBP

O 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 4(a), considere os P pixels da vizinhança, identificados por $g_p(x_p, y_p)$, em uma região da imagem com circunferência r, onde $p = \{0, ..., P-1\}$, e o pixel central $g_c = (0, 0)$, sendo o posicionamento de cada pixel da vizinhança (x_p, y_p), para $x_p = -Rsen(2\pi p/P)$ e $y_p = Rcos(2\pi p/P)$.

O valor de R determina a distância entre o pixel central e os pixels vizinhos que serão considerados na computação do LBP. A Figura 4(b) ilustra a etapa subsequente à

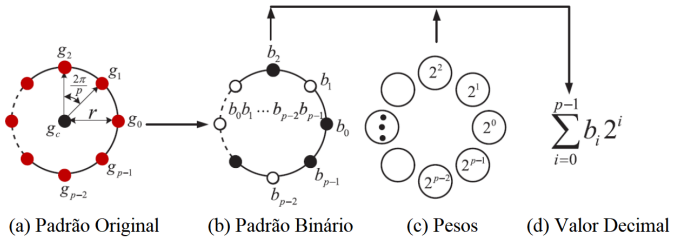

Figura 4. Método da extração de atributos LBP.

comparação dos pixels da vizinhança com o pixel central. Na Figura 4(c) a associação de cada posição dos bits com os pesos, em potência de 2, sobre a região circular e na Figura 4(d) a representação matemática do valor decimal gerado. Assim, temos que

$$LBP_{(P,R)} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \qquad s(g_p - g_c) = \begin{cases} 1 & \text{se } g_p - g_c \geq 0 \\ 0 & \text{caso contrário.} \end{cases} \tag{3}$$

Variantes mais robustas do LBP, como o LBP Uniforme (U-LBP) (Haq et al., 2017), LBP Invariante à Rotação (IR-LBP) (Moore and Bowden, 2011) e LBP Uniforme e Invariante à Rotação (UIR-LBP) (Wang et al., 2014) são encontradas na literatura. Considerando as características de uniformidade de textura do conjunto de dados, realizamos os experimentos com o método U-LBP.

Na primeira linha da Figura 5 são apresentados exemplos de imagens EL de células FVs, com os destaques vermelhos nos defeitos de microtrincas, imperceptíveis a um especialista em uma primeira análise. Na segunda linha ilustra-se as imagens resultantes da aplicação do U-LBP às primeiras, nas quais se observa 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.

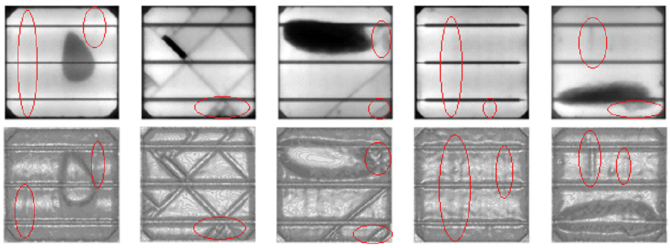

Figura 5. Imagens de células FVs e o resultado da aplicação do U-LBP.

4.3 CNN Customizada

Em geral, uma CNN é composta por três tipos de camadas de processamento: convolução (C), *pooling* (P) e totalmente conectadas, do inglês *fully connected* (FC). As duas primeiras realizam a extração de características das imagens e a última mapeia os recursos extraídos para classificação. A Figura 6 ilustra a representação da CNN Customizada. Sua entrada recebe os atributos de textura produzidos pelo método LBP. A topologia proposta é composta 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 6 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.

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

	Valor Predito	
	Defeito	Sem Defeito
Defeito	98	6
Sem Defeito	8	100

5. METODOLOGIA DE AVALIAÇÃO

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

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

$$A_c = \frac{VP + VN}{VP + FP + VN + FN}, \tag{4}$$

$$S_e = \frac{VP}{VP + FN}, \tag{5}$$

e

$$E_s = \frac{VN}{VN + FP}. \tag{6}$$

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.

6. ANÁLISE E APRESENTAÇÃO DOS RESULTADOS

A Tabela 1 apresenta a matriz de confusão resultante da validação cruzada do modelo computacional. O modelo classificou corretamente 100 células FVs como não defeituosas e 98 como defeituosas, classificando de forma incorreta 6 células FVs defeituosas como não defeituosas (erro tipo 1) e 8 células não defeituosas como defeituosas (erro tipo 2) obtendo uma Acurácia, Sensibilidade e Especificidade de $A_c = 94\%$, $S_e = 92\%$ e $E_s = 94\%$, respectivamente. O método se mostrou mais eficiente em detectar células FVs não defeituosas do que 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.

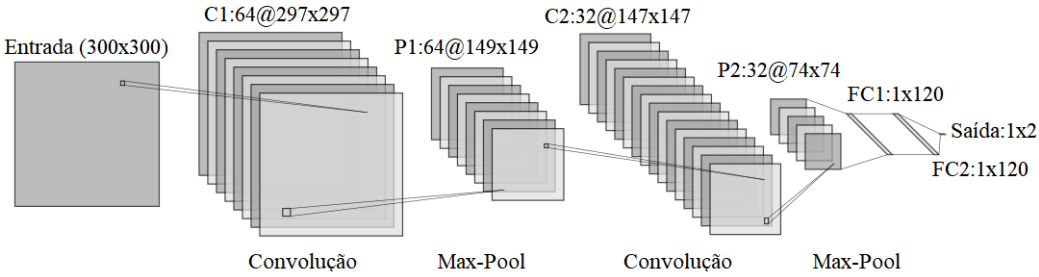

Figura 6. Topologia da Rede Neural Convolucional Customizada.

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

Autores	Algoritmo proposto	Total de parâmetros	Acurácia
(Deitsch et al., 2019)	*SVM*	-	84%
	VGG19	140.10^6	88%
(Akram et al., 2019)	VGG11	130.10^6	93%
Outras topologias	InceptionV3	24.10^6	88%
	VGG16	120.10^6	88%
Proposta deste trabalho	Rede Neural Convolucional Customizada	21.10^6	94%

Na Tabela 2 apresentam-se os resultados de acurácia dos modelos propostos por outros autores e que também empregam CNNs em sua implementação, utilizando a mesma base de dados proposta por (Buerhop-Lutz et al., 2018; Deitsch et al., 2019) utilizada neste trabalho. 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 reportamos ($A_c = 94\%$). Apesar de possuir menos parâmetros que os demais modelos, a CNN Customizada se mostra competitiva, em termos de acurácia, que as demais redes, com menor complexidade e menor custo computacional para o treinamento da rede.

7. CONCLUSÕES

Neste artigo foi proposto um modelo para detecção de defeitos em células FVs de $Si-m$ a partir de imagens ELs. O estudo revelou que o pré-processamento das imagens utilizando o Filtro Bilateral Gaussiano e o método LBP realça os defeitos das células FVs nas imagens. A análise indicou que a CNN Customizada possui baixa complexidade em termos de número de parâmetros quando comparada a topologias tradicionais de CNN, mantendo um desempenho satisfatório na classificação de defeitos em células FVs. O modelo proposto demonstrou competitividade em relação à acurácia, quando comparado aos trabalhos relevantes da literatura. Além disso, o modelo se mostrou apropriado para o problema de detecção de defeitos em células FVs, evidenciando menor erro na identificação das células não defeituosas em comparação com as defeituosas.

REFERÊNCIAS

Akram, M.W., Li, G., Jin, Y., Chen, X., Zhu, C., Zhao, X., Khaliq, A., Faheem, M., and Ahmad, A. (2019). CNN based automatic detection of photovoltaic cell defects in electroluminescence images. *Energy*, 189, 116319.

Buerhop-Lutz, C., Deitsch, S., Maier, A., Gallwitz, F., Berger, S., Doll, B., Hauch, J., Camus, C., and Brabec, C.J. (2018). A benchmark for visual identification of defective solar cells in electroluminescence imagery. In *European PV Solar Energy Conference and Exhibition (EU PVSEC)*.

Chaudhary, A.S. and Chaturvedi, D.K. (2018). Analyzing defects of solar panels under natural atmospheric conditions with thermal image processing. *International Journal of Image, Graphics and Signal Processing*, 10(6), 10–21.

Deitsch, S., Christlein, V., Berger, S., Buerhop-Lutz, C., Maier, A., Gallwitz, F., and Riess, C. (2019). Automatic classification of defective photovoltaic module cells in electroluminescence images. *Solar Energy*, 185, 455–468.

Fan, T., Sun, Tao, Xie, Xiangying, Liu, Hu, and Na, Z. (2022). Automatic micro-crack detection of polycrystalline solar cells in industrial scene. *IEEE Access*, 10, 16269–16282.

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

Haq, E.U., Huarong, X., and Khattak, M.I. (2017). Notice of retraction: Face recognition by svm using local binary patterns. In *2017 14th Web Information Systems and Applications Conference (WISA)*, 172–175.

Moore, S. and Bowden, R. (2011). Local binary patterns for multi-view facial expression recognition. *Computer Vision and Image Understanding*, 115(4), 541–558.

Ojala, T., Pietikainen, M., and Harwood, D. (1994). Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. In *Proceedings of 12th International Conference on Pattern Recognition*, volume 1, 582–585.

Simonyan and Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. In *3rd International Conference On Learning Representations (ICLR 2015)*, volume 1, 1–14. Computational and Biological Learning Society.

Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A.A. (2016). Inception-v4, inception-resnet and the impact of residual connections on learning. *ArXiv*,

abs/1602.07261.

Tang, W., Yang, Q., Hu, X., and Yan, W. (2022). Convolution neural network based polycrystalline silicon photovoltaic cell linear defect diagnosis using electroluminescence images. *Expert Systems with Applications*, 202, 117087.

Tang, W., Yang, Q., Xiong, K., and Yan, W. (2020). Deep learning based automatic defect identification of photovoltaic module using electroluminescence images. *Solar Energy*, 201, 453–460.

Wang, Y., Zhao, Y., and Chen, Y. (2014). Texture classification using rotation invariant models on integrated local binary pattern and zernike moments. *EURASIP Journal on Advances in Signal Processing*, 2014(1), 182.