



Computational Model for Discriminating Defective Photovoltaic Cells in Electroluminescent Images.

Alan M. da Rocha, Marcelo M. S. de Souza,
Francilândio L. Serafim, Carlos A. R. Fernandes and
Ícaro B. Viana

EasyChair preprints are intended for rapid
dissemination of research results and are
integrated with the rest of EasyChair.

November 14, 2023

Modelo computacional para discriminação de células fotovoltaicas defeituosas em imagens eletroluminescentes.

Alan M. da Rocha* Marcelo M. S. de Souza*
Francilândio L. Serafim** Carlos A. R. Fernandes* Ícaro B. Viana*

* 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, icaro.viana@ufc.br).

** Engenharia da Computação, Campus Sobral, Universidade Federal do Ceará, CE (e-mail: francilandiolima@alu.ufc.br).

Abstract: Photovoltaic (PV) energy production has grown worldwide, since it is a clean and affordable energy source. The most vulnerable component of the photovoltaic generation system is the PV cell, which operates under adverse environmental conditions, such as wind, rain, salinity and dust. Therefore, there is a demand for technologies that contribute to improve the efficiency and reliability of these systems, by automating the fault detection process in PVs cells. In this context, we propose a computational model that discriminates defective monocrystalline silicon PVs cells from texture attributes of electroluminescent images. We also added to the model a Custom Convolutional Neural Network (CNN) with fewer number of parameters than other traditional topologies. We assess the performance of the model, by cross-validation, with images with a widely used PV cells image dataset. The reduction of parameters that we promoted in the Custom CNN did not compromise the performance of the model, showing results consistent with those reported in literature. Thus, the model fits to the problem of defect detection in PV cells, since it properly detects 94% of defective cells and 86% of non-defective ones.

Resumo: A geração de energia fotovoltaica (FV) tem crescido mundialmente por ser uma energia limpa e de custo acessível. O componente mais vulnerável nos sistemas de geração fotovoltaicos é a célula FV, que opera sob condições ambientais adversas, como vento, chuva, salinidade e poeira. Logo, existe demanda por tecnologias que contribuam para melhorar a eficiência e a confiabilidade desses sistemas, pela automação do processo de detecção de defeitos em células FVs. Neste contexto, propomos um modelo computacional que discrimina células FVs de silício monocristalino defeituosas a partir de atributos de textura de imagens eletroluminescentes. Adicionamos também ao modelo uma Rede Neural Convolutiva (CNN) Customizada com menor número de parâmetros que outras topologias de redes tradicionais. Avaliamos o desempenho do modelo, por validação cruzada, com uma base de imagens de células FVs amplamente utilizada. A redução dos parâmetros que promovemos na CNN Customizada não comprometeu o desempenho do modelo, apresentando resultados compatíveis aos reportados na literatura. Logo, o modelo adequa-se ao problema de detecção de defeitos em células FVs, pois detecta corretamente 94% das células defeituosas e 86% das não defeituosas.

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

Palavras-chaves: Detecção de Falhas; Célula Fotovoltaica; Rede Neural Convolutiva; 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 recebem manutenções preventivas. Desta forma, esses ficam susceptíveis 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) (Deutsch 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).

Propomos um modelo computacional que discrimina células FVs de silício monocristalino (*Si-m*) defeituosas a partir de imagens EL. Esse, baseia-se na extração de atributos de textura das imagens, pelo método *Local Binary Pattern* (LBP), e a subsequente classificação das células FVs, como funcionais ou defeituosas, por uma Rede Neural Convucional, do inglês *Convolutional Neural Network* (CNN). Além do modelo em questão, destacamos como contribuição uma topologia de rede convolucional, a qual denominamos como CNN Customizada, que é mais competitiva, em desempenho e complexidade, do que as topologias de rede de uso geral, como a VGG (Simonyan and Zisserman, 2015), a Inception e ResNet (Szegedy et al., 2016), em problemas de identificação de defeitos em células FVs.

Organizamos este artigo em seções da seguinte forma: na Seção 2 trazemos trabalhos relacionados ao tema deste artigo; na Seção 3 apresentamos a base de imagens com a qual validamos o nosso modelo; na Seção 4 descrevemos nosso modelo computacional e detalhamos os seus três componentes, que são o filtro de pré-processamento, o método de extração de atributos de textura LBP e a CNN customizada; na Seção 5 apresentamos a metodologia de avaliação do modelo; na Seção 6 discutimos os resultados obtidos; na Seção 7 fechamos o artigo com nossas conclusões.

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 silício policristalino. 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.

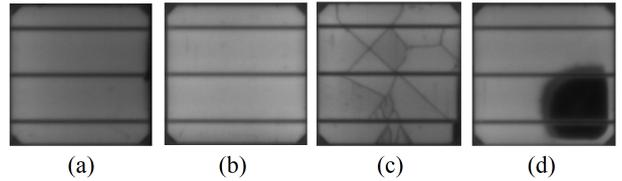


Figura 1. Células de *m-Si* (a) e (b) Condições normais de funcionamento. (c) Defeito ocasionado por trincas. (d) Elevado grau de sombreamento.

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%. Deutsch et al. (2019) propuseram um modelo com um classificador *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); Deutsch 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 e perspectiva, e rotuladas em funcionais e defeituosas, com vários graus de degradação. Nas Figuras 1(a) e 1(b), temos imagens EL de células FVs não defeituosas e nas Figuras 1(c) e 1(d) defeituosas, com trincas e áreas sombreadas respectivamente.

4. MODELO PROPOSTO

Ilustramos nosso modelo computacional na Figura 2. As etapas de Pré-Processamento e de Extração de Características (Fases 1 e 2) são responsáveis em aprimorar e realçar as características dos defeitos nas imagens eletroluminescentes brutas, pela aplicação do filtro Gaussiano Bilateral e pelo extrator de texturas LBP. Esse último produz a representação das texturas codificadas como imagens, que alimentam o treinamento e teste da CNN customizada (Fase 3). Além de refinar a extração de características, essa última classifica as células FVs como defeituosas ou não defeituosas.

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

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

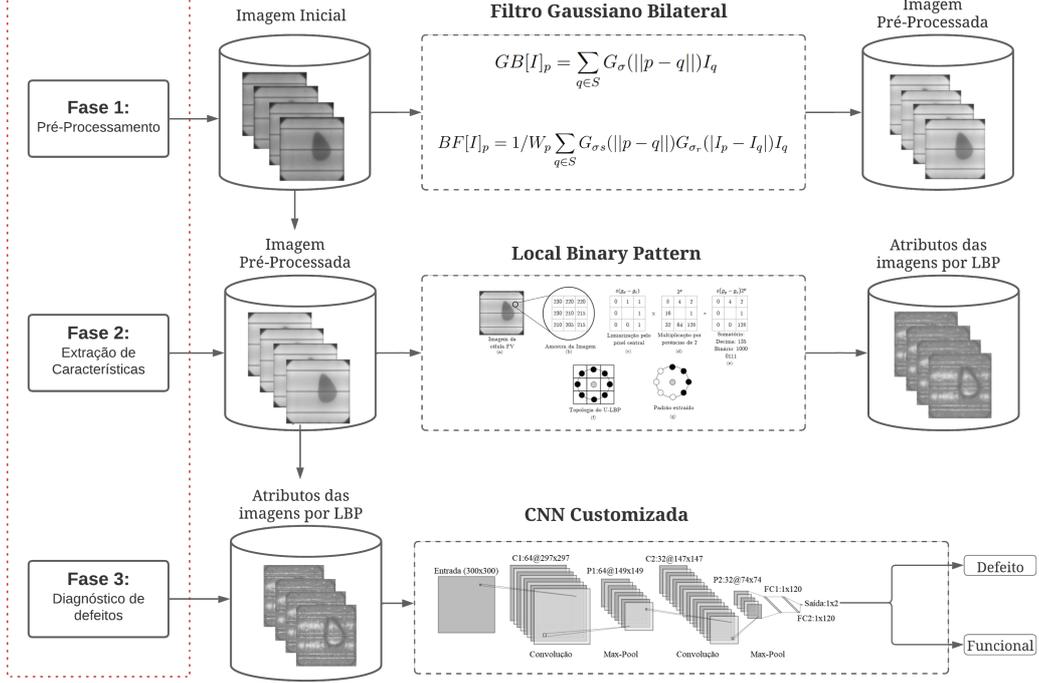


Figura 2. Modelo para detecção de defeitos em células fotovoltaicas a partir de imagens de eletroluminescência

este filtra ruídos, suavizando áreas homogêneas, preservando as informações das bordas (Garg, 2020). O filtro de desfoque Gaussiano é definido por

$$GB[I]_p = \sum_{q \in S} G_{\sigma}(\|\mathbf{p} - \mathbf{q}\|) I_q \quad (1)$$

, em que $GB[I]_p$ é a saída do filtro do pixel p após o desfoque. O lado direito de (1) representa o somatório de todos os pixels I_q com $q \in S$ pela função Gaussiana G_{σ} , \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_p e I_q . Já o filtro Gaussiano Bilateral é dado por

$$BF[I]_p = 1/W_p \sum_{q \in S} G_{\sigma_s}(\|\mathbf{p} - \mathbf{q}\|) G_{\sigma_r}(|I_p - I_q|) I_q \quad (2)$$

em que $1/W_p$ 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.

Adotamos no modelo os parâmetros $1/W_p = 1/255$ e $\sigma_s = \sigma_r = 15$. Esses valores permitem normalizar a intensidade

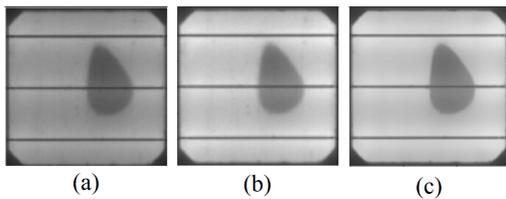


Figura 3. (a) Imagem original. (b) Imagem em níveis de cinza. (c) Resultado da aplicação do filtro Gaussiano Bilateral.

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 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 preserve 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.

4.2 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 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 $p = \{0, \dots, P-1\}$, 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, temos que

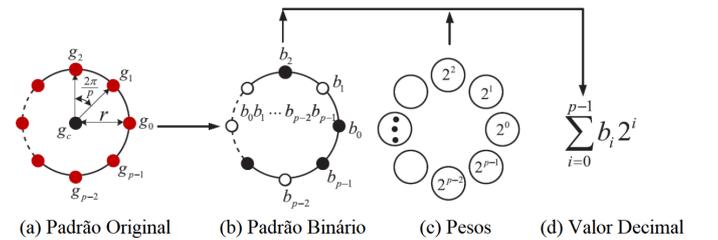


Figura 4. Método da extração de atributos LBP.

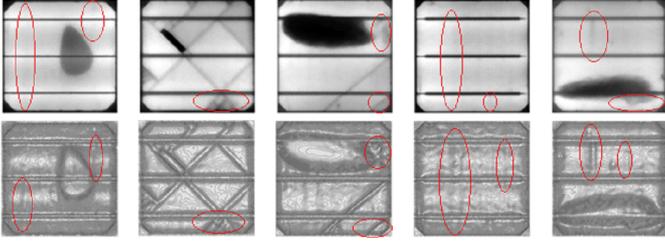


Figura 5. Imagens de células FVs e o resultado da aplicação do U-LPB.

$$LBP_{(P,R)} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \quad (3)$$

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

Na Figura 4(b) temos a etapa subsequente à 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.

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 nossos experimentos com o método U-LBP.

Na primeira linha da Figura 5 estão exemplos de imagens eletroluminescentes 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.

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. Temos na Figura 6 a representação da Rede Neural Convolutiva Customizada. Sua entrada recebe os atributos de textura produzidos pelo método LBP. A topologia que propomos 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 previsões realizadas pelo modelo.

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

5. METODOLOGIA DE AVALIAÇÃO

Avaliamos o desempenho do modelo por validação cruzada, aonde dividimos as 1074 imagens, aleatoriamente, em grupos de teste e treino (20% e 80%). Treinamos a CNN Customizada 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, calculamos as métricas de avaliação Acurácia (A_c), Sensibilidade (S_e) e Especificidade (E_s) pelas equações:

$$A_c = \frac{VP + VN}{VP + FP + VN + FN}, \quad (4)$$

$$S_e = \frac{VP}{VP + FN}, \quad (5)$$

e

$$E_s = \frac{VN}{VN + FP}. \quad (6)$$

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

Na Tabela 1 observamos 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, temos 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.

Na Tabela 2 temos 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 reportamos ($A_c = 88\%$). Apesar de ter menos parâmetros que os demais modelos, a CNN Customizada mostra-se competitiva, em termos de acurácia, que as demais redes, com menor complexidade e menor custo computacional para o treinamento da rede.

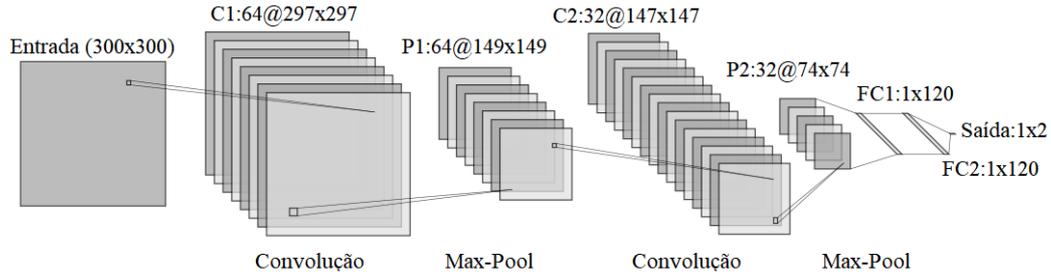


Figura 6. Topologia da Rede Neural Convolucional Customizada.

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%
Nossa Proposta	Rede Neural Convolucional Customizada	21.10 ⁶	88%

7. CONCLUSÕES

Propusemos um modelo para detecção de defeitos em células FVs de $Si - m$ a partir de imagens ELs. Mostramos 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, que 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 que levantamos 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.

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.