



Defect Analysis in Photovoltaic Cells Using the Gray-Level Co-Occurrence Matrix

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.

October 23, 2023

Análise de Defeitos em Células Fotovoltaicas Através da Matriz de Coocorrência de Níveis de Cinza

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: The increasing global demand for electricity and the environmental impacts caused by thermal power generation have led to investments in renewable energy sources, such as photovoltaic solar energy (PV). However, the growth of installed capacity in photovoltaic generation systems requires intelligent systems to detect faults in their components, particularly in PV cells. As converters of solar energy into electricity, the latter operate exposed to adverse environmental conditions such as wind, rain, salinity, and dust, which degrade and compromise the efficiency and reliability of the generation system. In this context, an intelligent system is proposed in this study for the detection of defects in PV cells using electroluminescence (EL) images. This system is based on a supervised classification model, in which image features are represented by a texture descriptor constructed from the Gray-Level Co-occurrence Matrix. The model was evaluated through cross-validation on a public dataset of 2624 PV cell images, demonstrating sensitivity to defects such as shading, hotspots, cracks, and microfissures. Its best performance was achieved with the Random Forest (RF) classifier, yielding competitive results compared to those found in the literature. Thus, it presents a viable alternative for automated inspection of PV cells.

Resumo: A crescente demanda global por eletricidade e os impactos ao ambiente produzidos pela geração termoelétrica tem levado ao investimento em fontes de energia renováveis, como a energia solar fotovoltaica (FV). No entanto, o crescimento da capacidade instalada dos sistemas de geração fotovoltaicos exige sistemas inteligentes para detectar falhas em seus componentes, em particular nas células FV. Conversoras de energia solar em elétrica, essas últimas operam expostas a condições ambientais adversas, como vento, chuva, salinidade e poeira, que degradam e comprometem a eficiência e confiabilidade do sistema de geração. Nesse contexto, é proposto nesse trabalho um sistema inteligente para detecção de defeitos em células FVs a partir de imagens de eletroluminescência (EL). Esse sistema baseia-se em um modelo de classificação supervisionado, no qual as características das imagens são representadas por um descritor de textura construído a partir da Matriz de Coocorrência de Níveis de Cinza. O modelo foi avaliado por validação cruzada em uma base pública de 2624 imagens de células FVs, demonstrando sensibilidade aos defeitos de sombreamento, pontos de calor, trincas e microfissuras. O seu melhor desempenho foi obtido com o classificador Random Forest (RF), com resultados competitivos aos encontrados na literatura, sendo assim uma alternativa viável na inspeção automatizada de células FVs.

Keywords: Fault Detection; Photovoltaic Cell; Computer Vision; Gray-Level Co-occurrence Matrix;

Palavras-chaves: Detecção de falhas; Célula fotovoltaica; Visão computacional; Matriz de Coocorrência de Níveis de Cinza.

1. INTRODUÇÃO

As mudanças climáticas associadas à queima de combustíveis fósseis e a dependência mundial desses recursos tem fomentado a produção de energia elétrica a partir de fontes renováveis. Neste contexto, a energia solar tem se destacado como uma fonte limpa, ilimitada e acessível (Chaudhary and Chaturvedi, 2018). Os sistemas de geração fotovoltaica (FV) apresentam custos acessíveis de implantação, manutenção e operação (Guerriero et al., 2019), tendo como seu principal componente a célula FV. Essas últimas requerem inspeções periódicas para detecção e manutenção preventiva de defeitos, pois operam expostas a condições ambientais adversas, como vento, chuva, salinidade e poeira (Kim et al., 2017).

A detecção de defeitos nas células FVs pode ser realizada diretamente, por medidas obtidas do sistema, como tensão, corrente, potência e temperatura de operação (Sánchez-Pacheco et al., 2014), ou indiretamente, pela análise de imagens dos módulos, comumente obtidas por câmeras instaladas em Veículos Aéreos não Tripulados (VAnT). Embora a primeira abordagem tenha como vantagem a facilidade de obtenção de medidas, essa não discrimina algumas situações de falhas daquelas semelhantes às condições normais de operação (Basnet et al., 2020).

Um método amplamente utilizado na detecção de defeitos em células FVs é a inspeção de imagens de eletroluminescência (EL) (Tang et al., 2020). Essas imagens são produzidas a partir da radiação emitida pelos materiais semicondutores quando alimentados por uma fonte de corrente contínua. Nesse processo, a energia elétrica é convertida em luz visível ou infravermelha (Frazão et al., 2017), sendo que células defeituosas apresentarão uma redução ou perda total de emissão de radiação EL em regiões locais, resultando em áreas escuras nas imagens (Djordjevic et al., 2014).

Neste artigo, é proposto um modelo computacional para identificação de defeitos em células FVs de silício monocristalino (m -Si) a partir de imagens de EL. Um descritor de textura das imagens é construído usando a Matriz de Coocorrência de Níveis de Cinza (do inglês *Gray-Level Co-occurrence Matrix* (GLCM)), e o desempenho do modelo na classificação supervisionada de defeitos é avaliado em um conjunto de 2624 imagens. Nessa avaliação, são considerados os classificadores clássicos *Random Forest* (RF), *Support Vector Machine* (SVM), *Naive Bayes* (NB) e *k-Nearest Neighbors* (k-NN).

O modelo demonstrou sensibilidade aos defeitos de sombreamento, pontos de calor, trincas e microfissuras, com melhor desempenho de acurácia, precisão e sensibilidade para o classificador RF. Além disso, os resultados apresentados com esse classificador são competitivos aos encontrados na literatura, mostrando que o modelo proposto é uma alternativa promissora para a inspeção automatizada de células FVs.

O artigo foi organizado em seções da seguinte forma: na Seção 2, são apresentados os trabalhos relacionados ao tema do artigo; na Seção 3, são apresentados os conceitos

matemáticos da GLCM; na Seção 4 (Metodologia) são apresentadas a base de dados, o modelo computacional proposto e a estratégia empregada em sua avaliação; na Seção 5, são apresentados e discutidos os resultados obtidos e, por fim, o artigo é finalizado com as nossas conclusões na Seção 6.

2. TRABALHOS RELACIONADOS

Trabalhos recentes propuseram modelos para detecção e identificação de defeitos em células FVs por imagens EL. Em (Deutsch et al., 2019) são propostas duas abordagens para a detecção automática de defeitos em células FVs, onde foram realizados experimentos de classificação com 1968 imagens. Na primeira abordagem o resultado de acurácia obtido com o classificador SVM foi de 82,44%, e na segunda foi de 88,42% com uma *Convolutional Neural Network* (CNN). No trabalho de Shin et al. (2020) foram realizados experimentos de classificação com 2624 imagens e os classificadores SVM, RF, *Logistic regression* (LR), *Stochastic Gradient Descent* (SGD) e k-NN. Os resultados de acurácia obtidos foram: 64% (SVM e RF), 63% (LR e SGD) e 62% (k-NN).

Já em (Akram et al., 2019) foram ensaiadas as topologias VGG-19, VGG-16 e VGG-11 de CNNs na classificação de defeitos em células FVs, alcançando resultados de acurácia de até 93,02%. Em (Tang et al., 2020) foi avaliado o desempenho das redes convolucionais das topologias VGG-16, ResNet50, InceptionV3 e MobileNet, e uma rede generativa adversária para aumentar o número de imagens para treinamento. O melhor resultado obtido, em termos de acurácia, foi de 83%.

3. MATRIZ DE COCORRÊNCIA DE NÍVEIS DE CINZA

A GLCM (Haralick and Shapiro, 1992) representa a textura das imagens pela probabilidade de coocorrência de dois níveis de cinza i e j em uma vizinhança espacial pré-estabelecida. Para fins de notação, consideraremos a matriz GLCM, de dimensão $N \times N$ para uma imagem com N níveis de cinza, como sendo \mathfrak{C} . Seus elementos (c_{ij}) são determinados por

$$c_{ij} = |\{(i, j) : q \in V_p(d, \theta), i = \mathbf{I}(p), j = \mathbf{I}(p + q)\}|, \forall p \in \mathfrak{D}_I \quad (1)$$

, sendo $V_p(d, \theta)$ a função de vizinhança do pixel p , para um deslocamento $d \in \mathbb{Z}^+$, e uma direção θ . $\mathbf{I}(p + q)$ é uma translação de $\mathbf{I}(p)$ por q e o operador $|\cdot|$ denota a cardinalidade, ou seja, o número de elementos do conjunto.

A Figura 1 ilustra o cálculo de \mathfrak{C} para uma imagem com quatro níveis de cinza e critério de vizinhança $\theta = 0^\circ$ e $d = 1$. Observam-se destacadas na Figura 1(a) todas as coocorrências cujas intensidades dos pixels sejam 2 e 3, conforme o critério de vizinhança pré-estabelecido. Na Figura 1(b) temos a \mathfrak{C} correspondente, com destaque para o total das coocorrências encontradas em \mathbf{I} .

Tabela 1. Atributos de \mathcal{C} empregados na construção do descritor das imagens.

Atributo	Definição	Equação
Contraste	Medida da similaridade entre a intensidade de um pixel e sua vizinhança.	$Con = \sum_{i,j=0}^{N-1} i-j ^k (\hat{c}_{ij})^l$
Homogeneidade	Avalia o quanto a distribuição dos elementos da GLCM está próxima da diagonal.	$Hom = \sum_{i,j=0}^{N-1} \frac{\hat{c}_{ij}}{1+ i-j }$
Entropia	Medida da aleatoriedade das coocorrências dos níveis de cinza da GLCM.	$Ent = \sum_{i,j=0}^{N-1} \hat{c}_{ij} \ln(\hat{c}_{ij})$
Segundo momento angular	Mede a homogeneidade da GLCM pela correlação de seus elementos.	$ASM = \sum_{i,j=0}^{N-1} \hat{c}_{ij}^2$

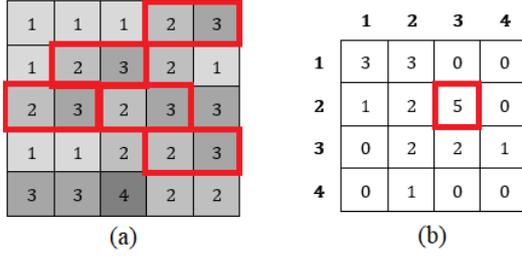


Figura 1. (a) \mathbf{I} contendo $N = 4$ níveis de cinza. (b) Exemplo de \mathcal{C} para a vizinhança de um pixel à direita ($d = 1, \theta = 0^\circ$).

4. METODOLOGIA

4.1 Base de Imagens

Adota-se neste trabalho a base de imagens de EL de células FVs proposta por Buerhop-Lutz et al. (2018); Deitsch et al. (2018)¹, tendo em vista que essa tem sido amplamente utilizada na literatura para fins de investigação do problema proposto.

Essa base contém 2624 amostras de imagens de EL de células FVs, sendo 1074 de *m-Si* e 1550 de silício policristalino (*p-Si*), codificadas em escala de cinza e 8 bits, dimensionadas em 300×300 pixels com diferentes graus de degradação. As imagens são anotadas com uma probabilidade de defeito $P_d \in [0, 1]$, bem como o tipo de módulo solar a que pertencem (*m-Si* ou *p-Si*). Neste trabalho, são consideradas apenas as imagens de células de *m-Si* e, com base em P_d , as imagens são divididas em duas categorias: defeituosas (classe positiva, com $P_d > 0.5$) e funcionais (classe negativa, com $P_d < 0.5$).

A Figura 2 apresenta quatro amostras de imagens EL de células FVs do tipo *m-Si*, extraídas da base. As Figuras 2(a) e 2(b) ilustram imagens de células funcionais e as Figuras 2(c) e 2(d), imagens de células com defeitos de trincas e sombreamento, respectivamente.

4.2 Extração de atributos

Os descritores de textura das imagens das células FVs foram construídos a partir dos atributos de \mathcal{C} apresentados na Tabela 1. Também denominados de estatísticas de coocorrência, esses atributos são calculados a partir de \mathcal{C} normalizada ($\hat{\mathcal{C}}$), cujos elementos são

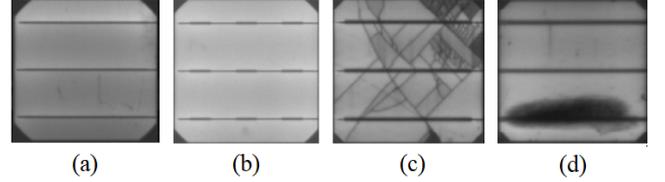


Figura 2. Células de *m-Si* (a) e (b): Condições normais de funcionamento. (c): Defeitos ocasionados por trincas. (d): Elevado grau de sombreamento.

$$\hat{c}_{ij} = \frac{c_{ij}}{\sum_{i,j=0}^{N-1} c_{ij}}. \quad (2)$$

A Figura 3 ilustra o método para o cálculo dos atributos de \mathcal{C} . Calcula-se um conjunto de X matrizes de coocorrência representadas por

$$\mathbf{C} = \{\hat{\mathbf{C}}_1, \hat{\mathbf{C}}_2, \dots, \hat{\mathbf{C}}_X\} \quad (3)$$

, sendo $X = |\mathbf{d} \times \boldsymbol{\theta}|$ a cardinalidade do produto cartesiano dos conjuntos de deslocamentos $\mathbf{d} = \{1, 2, 4\}$ e direções $\boldsymbol{\theta} = \{0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}, \pi, \frac{5\pi}{4}, \frac{3\pi}{2}, \frac{7\pi}{4}\}$ para o cálculo das coocorrências. Assim, cada matriz em \mathbf{C} corresponde às coocorrências da imagem de entrada para uma tupla $(d, \theta) \in \mathbf{d} \times \boldsymbol{\theta}$.

Os cálculos foram realizados em quatro regiões de interesse (ROIs) (Figura 4). Essas são delimitadas por três estruturas horizontais denominadas de *busbars* (BB), que são filamentos metálicos para a condução de corrente elétrica através das células FVs.

Foram obtidos portanto, quatro conjuntos de matrizes de coocorrência $\mathbf{C}_1, \mathbf{C}_2, \mathbf{C}_3$ e \mathbf{C}_4 , um para cada ROI, e construiu-se o descritor da imagem com a concatenação das estatísticas de coocorrência (Tabela 1) de todas as matrizes.

4.3 Validação do modelo

Os modelos foram avaliados por validação cruzada, pelo método *k-fold* ($k = 3$), conforme o fluxo apresentado na Figura 5. Primeiramente, as variáveis foram normalizadas para se obter média zero e variância unitária. As validações foram realizadas com os classificadores RF, SVM, NB e k-NN, sendo repetidas para cada classificador, buscando-se incrementalmente os k_m melhores atributos que maximizem a acurácia. A classe *GridSearchCV* da biblioteca

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

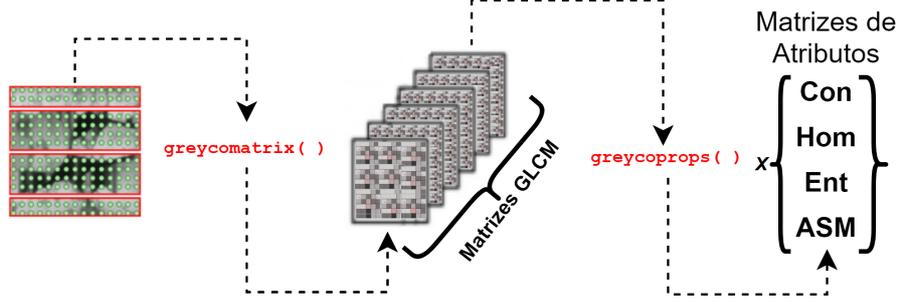


Figura 3. Obtenção das \mathcal{C} s e atributos das imagens da célula FV.

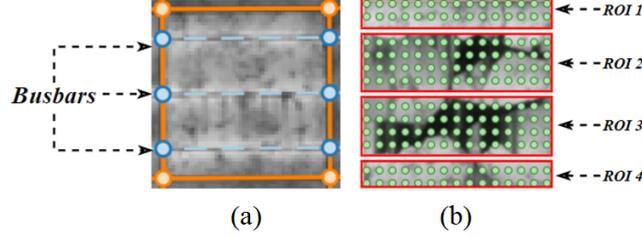


Figura 4. (a) *Busbars* das células FVs. (b) Regiões de interesse da célula FV.

sklearn foi utilizada para encontrar a combinação ideal de hiperparâmetros de cada modelo.

As métricas de desempenho empregadas são a acurácia (*acc*), sensibilidade (S_s), precisão (P) e $F - Score$:

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

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

$$P = \frac{VP}{VP + FP}, \quad (6)$$

$$F - Score = \frac{(2 \times P \times S_s)}{(P + S_s)}. \quad (7)$$

Nas Equações 4, 5 e 6: VP é o total de células FVs classificadas corretamente como defeituosas, VN o total daquelas classificadas corretamente como funcionais, FP as classificadas defeituosas sendo funcionais e FN as classificadas funcionais sendo defeituosas.

5. RESULTADOS E DISCUSSÕES

A Tabela 2 apresenta os resultados do primeiro experimento de validação cruzada, onde os resultados da acurácia dos classificadores foram calculados. Em todos os experimentos, foram escolhidos os 880 melhores atributos de \mathcal{M}_c , pois não ocorreram alterações nas referidas métricas para valores acima desse ponto. Em negrito, destacam-se os melhores resultados de cada classificador, onde o RF obteve o melhor desempenho, com 0,90 de acurácia e um desvio padrão (σ) de $\pm 0,03$, seguidos pela SVM, NB e k-NN, que obtiveram 0,87, 0,85 e 0,84 de acurácia, respectivamente.

Tabela 2. Resultado da *acc* e σ dos classificadores.

Atributos	RF	SVM	NB	k-NN
80	0,85 \pm 0,06	0,81 \pm 0,07	0,81 \pm 0,07	0,83 \pm 0,07
180	0,89 \pm 0,05	0,87 \pm 0,05	0,82 \pm 0,05	0,81 \pm 0,06
280	0,89 \pm 0,05	0,85 \pm 0,05	0,83 \pm 0,07	0,84 \pm 0,05
380	0,89 \pm 0,05	0,85 \pm 0,04	0,81 \pm 0,07	0,84 \pm 0,08
480	0,90 \pm 0,03	0,85 \pm 0,06	0,82 \pm 0,06	0,82 \pm 0,06
580	0,89 \pm 0,04	0,85 \pm 0,03	0,82 \pm 0,05	0,82 \pm 0,07
680	0,88 \pm 0,04	0,84 \pm 0,05	0,83 \pm 0,03	0,80 \pm 0,06
780	0,87 \pm 0,05	0,84 \pm 0,04	0,85 \pm 0,04	0,83 \pm 0,06
880	0,88 \pm 0,02	0,85 \pm 0,04	0,83 \pm 0,02	0,82 \pm 0,04

Na Tabela 3 são apresentadas as medidas de S_s dos quatro classificadores. A métrica obtida por eles estima a probabilidade das células com defeito e funcionais serem classificadas de acordo com a sua respectiva classe, isto quer dizer por exemplo que, para um conjunto de 100 células FVs defeituosas, com $S_s = 0,93$, mostra que o classificador realizou a predição corretamente de 93 das 100 imagens. Neste caso, verifica-se que o classificador RF obteve o melhor resultado com $S_s = 0,90$ e $\sigma = \pm 0,05$, seguido dos classificadores NB e k-NN com 0,86 e SVM com $S_s = 0,85$.

Tabela 3. Resultado da S_s e σ dos classificadores.

Atributos	RF	SVM	NB	k-NN
80	0,85 \pm 0,04	0,83 \pm 0,05	0,84 \pm 0,07	0,83 \pm 0,05
180	0,84 \pm 0,08	0,84 \pm 0,06	0,85 \pm 0,07	0,86 \pm 0,06
280	0,85 \pm 0,07	0,83 \pm 0,05	0,86 \pm 0,07	0,86 \pm 0,07
380	0,86 \pm 0,08	0,85 \pm 0,07	0,87 \pm 0,05	0,86 \pm 0,08
480	0,85 \pm 0,09	0,85 \pm 0,08	0,85 \pm 0,07	0,84 \pm 0,05
580	0,86 \pm 0,05	0,82 \pm 0,09	0,84 \pm 0,13	0,86 \pm 0,06
680	0,88 \pm 0,06	0,83 \pm 0,07	0,84 \pm 0,07	0,85 \pm 0,07
780	0,87 \pm 0,04	0,84 \pm 0,08	0,86 \pm 0,07	0,85 \pm 0,07
880	0,90 \pm 0,05	0,85 \pm 0,05	0,84 \pm 0,02	0,84 \pm 0,06

A Tabela 4 apresenta as medidas de P . Observamos que a probabilidade da predição positiva estar correta foi bem

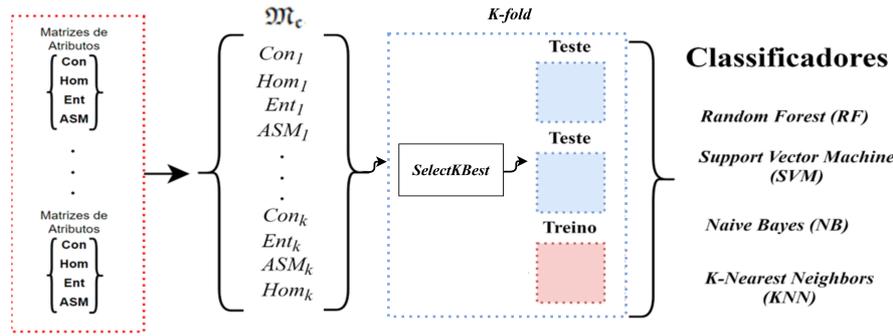


Figura 5. Cálculo das propriedades de textura e validação cruzada pelo método k -fold.

avaliada por todos os classificadores, sendo o NB mais bem avaliado com uma precisão de 0,94 e $\sigma = \pm 0,04$, seguindo do RF e k-NN com 0,94 e $\sigma = \pm 0,05$. Por fim, a SVM obteve o menor valor de P , mas ainda assim competitiva ($S_s = 0,90$ e $\sigma = \pm 0,05$). Os resultados da Tabela 4 demonstram que tanto as células defeituosas quanto as funcionais foram bem classificadas pelos modelos.

Tabela 4. Resultado da P e σ dos classificadores.

Atributos	RF	SVM	NB	k-NN
80	0,92±0,06	0,92±0,08	0,91±0,04	0,93±0,05
180	0,91±0,06	0,89±0,08	0,91±0,06	0,93±0,07
280	0,90±0,06	0,89±0,06	0,91±0,05	0,93±0,05
380	0,93±0,06	0,89±0,04	0,92±0,07	0,94±0,05
480	0,91±0,03	0,90±0,05	0,93±0,06	0,93±0,06
580	0,93±0,03	0,88±0,07	0,94±0,04	0,91±0,06
680	0,91±0,05	0,88±0,05	0,94±0,05	0,92±0,05
780	0,92±0,04	0,88±0,06	0,94±0,06	0,92±0,04
880	0,94±0,05	0,86±0,05	0,94±0,04	0,92±0,05

Tabela 5. Resultado de F -Score e σ dos classificadores.

Atributos	RF	SVM	NB	k-NN
80	0,86±0,05	0,88±0,06	0,83±0,05	0,83±0,07
180	0,87±0,04	0,87±0,04	0,81±0,08	0,82±0,04
280	0,88±0,05	0,85±0,04	0,80±0,06	0,81±0,05
380	0,88±0,05	0,87±0,05	0,80±0,05	0,82±0,06
480	0,89±0,05	0,85±0,06	0,80±0,07	0,82±0,08
580	0,88±0,04	0,86±0,05	0,80±0,07	0,81±0,04
680	0,90±0,05	0,85±0,05	0,80±0,07	0,82±0,05
780	0,88±0,04	0,86±0,05	0,80±0,07	0,83±0,05
880	0,89±0,05	0,86±0,04	0,80±0,06	0,82±0,06

Os resultados apresentados na Tabela 5, representam a combinação das métricas de P e S_s . O RF obteve um melhor desempenho com 0,90 e $\sigma = \pm 0,05$, seguidos da SVM, k-NN e NB com resultados de 0,88 e $\sigma = \pm 0,06$, 0,83 e $\sigma = \pm 0,05$, 0,83 e $\sigma = \pm 0,05$, respectivamente. Uma comparação das métricas obtidas através dos experimentos realizados com os classificadores foi essencial para encontrar o melhor modelo deste trabalho.

Foi realizada a média do F -Score e foi verificado o classificador que obteve a menor taxa de erro em suas análises. O resultado consolidado é apresentado na Tabela 6.

Tabela 6. Média F -Score dos classificadores.

F -Score	RF	SVM	NB	k-NN
Média	0,88±0,05	0,86±0,06	0,80±0,06	0,82±0,05

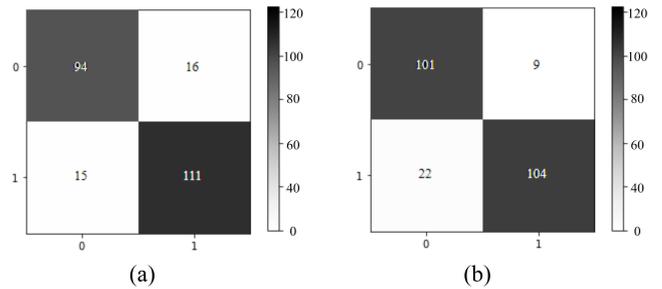


Figura 6. (a) Matriz de confusão para o RF no 1º teste. (b) Matriz de confusão do RF no 2º teste.

O RF apresentou um F -Score médio de 0,88 e $\sigma = \pm 0,05$, se destacando dentre os modelos utilizados neste trabalho. Um dos motivos para que o RF seja tão preciso em classificações binárias é que o mesmo realiza a combinação de um grande número de árvores de decisão (DTs), treinando cada uma em um conjunto ligeiramente diferente de observações, além de dividir os nós em cada árvore, considerando um número limitado de atributos. As previsões finais do RF são feitas pela média das previsões de cada árvore individual.

As previsões apresentadas nas Figuras 6(a) e 6(b) ilustram os resultados da classificação realizada pelo RF em dois testes distintos. No primeiro teste o RF classificou 94 imagens de células FVs defeituosas (VP) de forma correta, tendo uma classificação incorreta (FP) de 15 imagens. Já para a classificação de células funcionais (VN), o RF classificou 111 imagens de forma efetiva, contra 16 imagens que apresentaram problemas, mas foram classificadas como funcionais (FN). No segundo teste o RF classificou 101 imagens de células FVs defeituosas corretamente, classificando 22 imagens defeituosas como funcionais. Em relação as imagens funcionais, o RF classificou 104 imagens de forma efetiva, enquanto 9 imagens consideradas funcionais, foram classificadas com defeito.

A Figura 7(a) apresenta a imagem de uma célula FV que foi classificada como funcional na primeira validação, mas que possui microfissuras que podem diminuir a eficiência da célula. A Figura 7(b) ilustra uma célula FV que deveria ter sido classificada como defeituosa no primeiro teste, mas foi classificada como funcional. Já a Figura 7(c) ilustra a imagem de uma célula FV que foi classificada como funcional no segundo teste, mas que possui uma microfissura quase imperceptível. Por fim, a Figura 7(d) ilustra uma célula FV que deveria ter sido classificada

como defeituosa no segundo teste, mas que foi classificada como funcional.

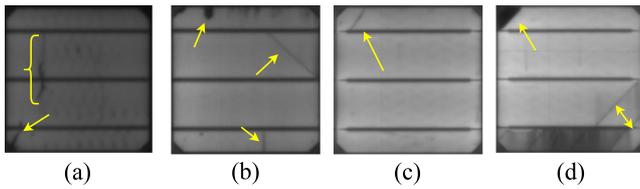


Figura 7. (a) FP do 1° teste com o RF. (b) FN do 1° teste com o RF. (c) FP do 2° teste com o RF. (d) FN do 2° teste com o RF.

A Figura 8 ilustra algumas imagens de células FVs que foram classificadas corretamente através do classificador RF. Observa-se que os defeitos ocasionados por trincas e microtrincas podem ser facilmente negligenciados por um especialista em uma primeira inspeção, tendo em vista que a avaliação visual em imagens sem a técnica EL pode dificultar a precisão da análise de defeitos em células FVs.

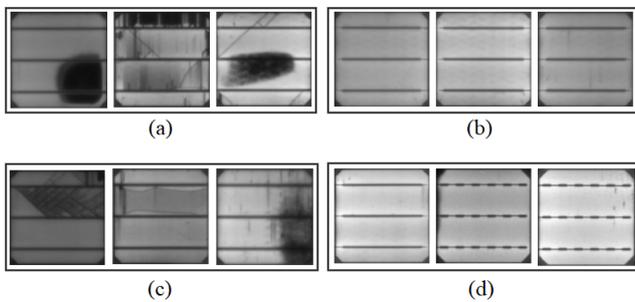


Figura 8. (a) e (c) Células FVs com defeito de trincas, microtrincas e pontos quentes classificadas corretamente pelo RF. (b) e (d) Células FVs funcionais classificadas corretamente pelo RF.

6. CONCLUSÕES

Neste trabalho é proposto um modelo computacional para a detecção de defeitos em células de módulos fotovoltaicos, de silício monocristalino, a partir de imagens de eletroluminescência. O uso de atributos de textura da matriz de coocorrência de níveis de cinza mostrou-se eficaz na classificação das células fotovoltaicas com defeitos de sombreamento, pontos de calor, trincas e microfissuras.

O *Random Forest* foi o classificador que apresentou melhor desempenho, com acurácia $acc = 0,90 \pm 0,03$ e $F-Score = 0,88 \pm 0,05$, sendo esses resultados competitivos em relação aos reportados na literatura. Conclui-se, portanto, que o modelo proposto é uma alternativa viável na inspeção automatizada de células FVs.

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.

Basnet, B., Chun, H., and Bang, J. (2020). An intelligent fault detection model for fault detection in photovoltaic systems. *Journal of Sensors*, 2020.

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*.

Deitsch, S., Buerhop-Lutz, C., Maier, A.K., Gallwitz, F., and Riess, C. (2018). Segmentation of photovoltaic module cells in electroluminescence images. Technical report.

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.

Djordjevic, S., Parlevliet, D., and Jennings, P. (2014). Detectable faults on recently installed solar modules in western australia. *Renewable Energy*, 67, 215–221.

Frazão, M., Silva, J., Lobato, K., and Serra, J. (2017). Electroluminescence of silicon solar cells using a consumer grade digital camera. *Measurement*, 99, 7–12.

Guerriero, P., Appiah, A.Y., Zhang, X., Ayawli, B.B.K., and Kyeremeh, F. (2019). Review and performance evaluation of photovoltaic array fault detection and diagnosis techniques. *International Journal of Photoenergy*, 2019, 6953530.

Haralick, R. and Shapiro, L. (1992). *Computer and Robot Vision*. New York.

Kim, D., Youn, J., and Kim, C. (2017). Automatic fault recognition of photovoltaic modules based on statistical analysis of uav thermography. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W6, 179–182.

Shin, H., Kang, J., and Gungor, O. (2020). Automatic classification of defective photovoltaic module cells in electroluminescence images. *University of California San Diego*.

Sánchez-Pacheco, F.J., Sotorrió-Ruiz, P.J., Heredia-Larrubia, J.R., Pérez-Hidalgo, F., and de Cardona, M.S. (2014). Plc-based pv plants smart monitoring system: Field measurements and uncertainty estimation. *IEEE Transactions on Instrumentation and Measurement*, 63(9), 2215–2222.

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.