

ESTRATÉGIAS PARA ANÁLISE DA EMISSÃO ELETROLUMINESCENTE DE MÓDULOS FOTOVOLTAICOS

Amanda Alvim – amandaalvim@id.uff.br
Gilberto Figueiredo – gilbertofigueiredo@id.uff.br
Universidade Federal Fluminense, Escola de Engenharia

Resumo. *O trabalho apresenta um levantamento bibliográfico das principais características para a avaliação de módulos fotovoltaicos a partir de sua emissão eletroluminescente com intuito de detectar defeitos de forma complementar aos métodos tradicionais de caracterização da geração fotovoltaica. São mostrados os aspectos gerais para a obtenção das imagens, além da descrição de métodos para o tratamento prévio das mesmas. Foram analisados os trabalhos correlatos que tratam da detecção de defeitos a partir das imagens em eletroluminescência, sendo que a tendência para a automatização do processo está relacionada com o desenvolvimento e a aplicação de inteligência artificial. Nesse contexto, os métodos de aprendizado de máquina se mostram promissores em relação à necessidade computacional e assertividade na detecção dos defeitos.*

Palavras-chave: *Eletroluminescência, Módulo fotovoltaico, Aprendizado de máquina*

1. INTRODUÇÃO

Com o aumento da participação da fonte solar fotovoltaica na matriz de eletricidade, o controle de qualidade do produto possui importância considerável nas linhas de produção de células e módulos fotovoltaicos (FV) e nos procedimentos de testes realizados nos órgãos responsáveis pelos requisitos de avaliação de conformidade. A garantia de que o mercado será abastecido com aplicações confiáveis pode ser realizada por meio de ensaios não destrutivos, os quais normalmente envolvem medição das características elétricas dos módulos FV.

Adicionalmente, métodos tradicionais de imagem são usados pelos fabricantes em suas linhas de produção, tais como a espectroscopia de corrente induzida por laser (LBIC) e a medida de corrente induzida por feixe de elétrons (EBIC). Mais recentemente, a técnica de eletroluminescência vem sendo utilizada na caracterização de células fotovoltaicas devido à sua praticidade e precisão tanto no mapeamento da distância de difusão de portadores minoritários de carga quanto na detecção de danos mecânicos, tais como as microfissuras nas células e falhas nos contatos elétricos.

As células FV são uma das várias aplicações das junções pn no campo da optoeletrônica: elas transformam energia de radiação eletromagnética em eletricidade. Já quando uma corrente elétrica é injetada no circuito ativo da célula, ela emite radiação. Este é o fenômeno chamado de eletroluminescência (EL) (Petraglia e Nardone, 2011). A radiação emitida pelos dispositivos FV não se encontra na faixa visível, mas na faixa do infravermelho (IR) do espectro eletromagnético, com comprimentos de onda entre 900 nm e 1300 nm, região conhecida como *Near Infrared* (NIR), não sendo possível observá-la a olho nu. Esta técnica é usada amplamente por fabricantes de células no processo de produção para avaliar a qualidade do produto (Fuyuki *et al.*, 2005; Köntges *et al.*, 2009).

Em se tratando das grandes centrais, o volume considerável de recursos que devem ser alocados para viabilizar os empreendimentos energéticos de grande porte baseados na conversão FV demandam garantias técnicas e financeiras estritas para garantir os índices de produtividade do sistema previstos em contrato. O controle de qualidade dos geradores FV tem o papel de suporte de tais garantias e tem sido realizado de forma sistemática tanto na recepção do material quanto nos procedimentos periódicos de operação e manutenção. As imagens em eletroluminescência servem de suporte ao controle de qualidade, uma vez que tendem a indicar efeitos imperceptíveis ao olho nu e que podem ser negligenciados ao analisar as características elétricas dos módulos e geradores FV, normalmente através de sua curva I-V.

O presente trabalho está inserido nesse contexto ao apresentar uma prospecção da literatura, na forma de revisão bibliográfica, com o intuito de apresentar os métodos para tratamento e análise das imagens em eletroluminescência de módulos e células FV visando a detecção e classificação automática dos defeitos a partir da utilização de modelos de aprendizado de máquina.

2. AQUISIÇÃO DE IMAGENS

A captura de imagens em EL é possível a partir da utilização de sensores que são sensibilizados no comprimento de onda da emissão produzida pelas células FV. Por exemplo, os detectores de fotodiodos à base de Arseneto de Índio Gálio (InGaAs) e Germânio (Ge) são amplamente utilizados no mercado, mais especificamente em soluções de aferições na faixa NIR. Os sensores de InGaAs são preferidos nesta faixa do IR devido a sua resposta melhor rápida, maior eficiência quântica, além de apresentar menor corrente de saturação reversa quando se considera uma mesma área de detecção.

Os sensores CCD (Dispositivo de Carga Acoplado) de câmeras convencionais à base de silício também são capazes de sensibilizar no comprimento de onda de eletroluminescência. Apesar de estes possuírem baixa eficiência quântica na faixa de maior emissão eletroluminescente (entre 1100 e 1200 nm), quando comparados com o sensor de InGaAs, os sensores CCD tem baixo custo e a resolução da imagem obtida é de boa qualidade, dependendo das condições de iluminação local (Figueiredo *et al.*, 2018). A Fig. 1 ilustra a eficiência de absorção para os sensores baseados em CCD e em InGaAs, onde é possível perceber que ambos, apesar de apresentarem níveis de absorção distintos, são sensibilizados na faixa do espectro da emissão eletroluminescente.

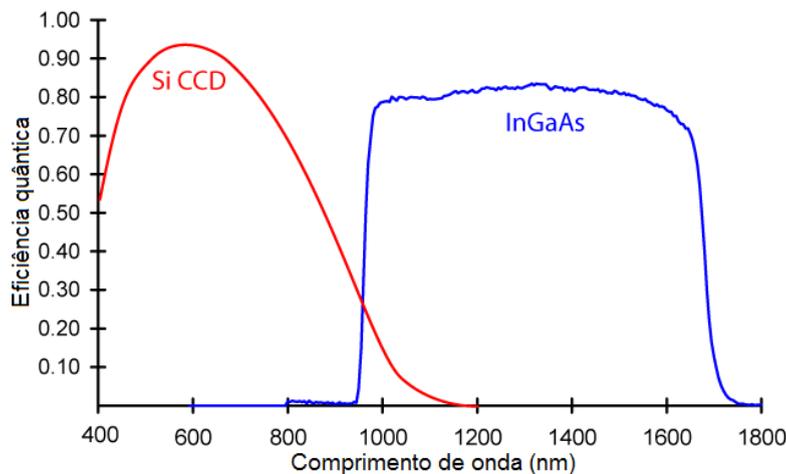


Figura 1 - Sensibilidade espectral dos sensores CCD de silício e à base de InGaAs. (Adaptado de Figueiredo *et al.*, 2018).

O procedimento para tomada das imagens é simples: o módulo fotovoltaico deve ser polarizado diretamente, com uma fonte em c.c., de maneira que a corrente flua pelo semicondutor. Na prática, deve-se utilizar uma fonte de corrente em c.c. com capacidade de controle em ambos os modos, de corrente e tensão, para que seja possível polarizar o módulo em condições específicas. Como em uma medida em iluminação, para se também aferir a curva I-V, sugere-se que seja realizada a aferição com quatro fios, para que as perdas ôhmicas no cabeamento não influenciem na medida da tensão. Deve-se, então, livrar completamente a superfície do dispositivo, realizar a medição preferencialmente com o módulo FV em local sem nenhuma iluminação, e polarizá-lo diretamente, de modo que a corrente flua pelo circuito através das resistências e do diodo, como mostra a Fig. 2.

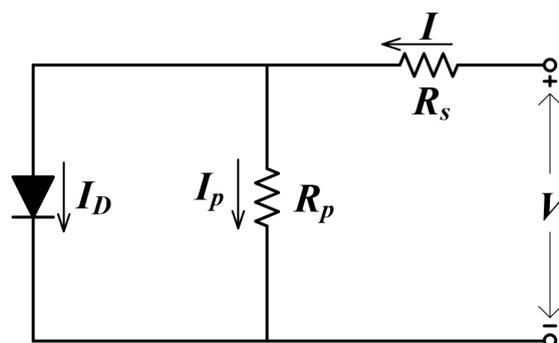


Figura 2 - Circuito equivalente do módulo FV polarizado para aquisição de imagens em eletroluminescência.

A IEC TS 60904-13 prevê diferentes níveis de corrente injetada de acordo com o objetivo pretendido no ensaio. Dependendo da qualidade da câmera utilizada e do tipo de defeito que se deseja detectar, faz-se necessário injetar níveis de corrente próximos da I_{sc} para obter uma imagem com brilho suficiente para observar o padrão da emissão das células, e a 10% de I_{sc} para detectar efeitos de *shunts* locais na célula. Também é possível acoplar filtros NIR (*Near Infrared*) no conjunto ótico da câmera para registrar as imagens sem a necessidade de um ambiente completamente escuro ou até mesmo em campo.

Um exemplo de imagem de EL de um módulo FV de silício policristalino, obtida através de uma solução de câmera comercial adaptada, com sensor CCD, registrada em I_{sc} , em condições de escuro, é mostrado na Fig. 3. Na mesma podem ser observados, além das imperfeições naturais do cristal devido ao processo de fabricação das células, alguns exemplos de defeitos detectáveis através de inspeção visual da imagem, tais como: microfissuras, delaminação e efeitos de entrada de umidade na parte ativa das células FV.

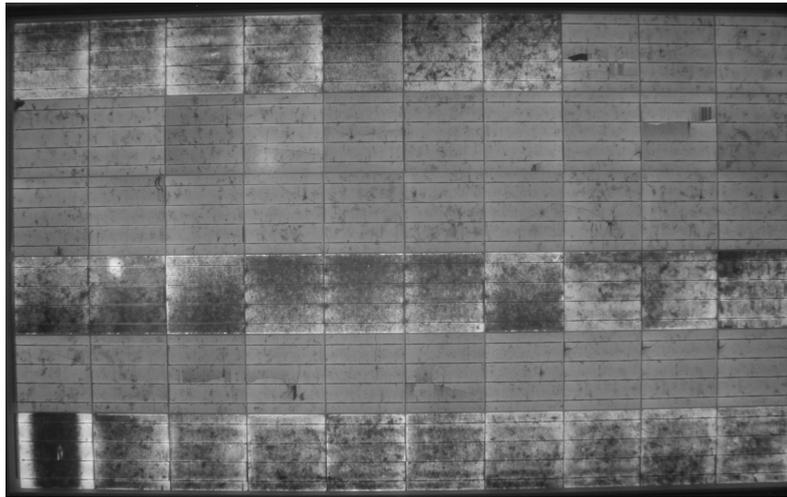


Figura 3 - Imagem EL de um módulo FV policristalino de 260 W.

3. TRATAMENTO DE IMAGENS

Com o crescente aumento das instalações fotovoltaicas, os métodos utilizados para inspeção dos módulos têm se mostrado cada vez mais desafiadores. Imagens em eletroluminescência são extremamente úteis para análises qualitativas, entretanto o processo de aquisição de boas imagens é demorado por exigir cuidado no ajuste de fatores como o foco, a orientação e a exposição, dificultando a utilização do método para avaliações em grande escala. Nesse sentido, para realizar o diagnóstico de um considerável número de equipamentos se faz necessário utilizar métodos automatizados para correção e análise das imagens.

Para a automatização é imprescindível desconsiderar as falhas inerentes ao processo de aquisição de imagens, tais como: ruídos, luz difusa, vinhetas e perspectiva. Desse modo, para minimizar os fatores que interferem no reconhecimento dos padrões, o programa deve ser capaz de realizar o pré-processamento para obter resultados mais precisos. Uma das formas de realizar a correção da perspectiva é apresentada por Mantel *et al.* (2018), onde são propostos métodos, utilizando o teorema fundamental da geometria projetiva, para dois casos. O primeiro caso se refere às imagens no mesmo plano do módulo, onde a correção consiste em uma exclusão das bordas irrelevantes e uma rotação da imagem em um ângulo pré-determinado. Para o segundo caso, as imagens foram obtidas em planos diferentes do plano do módulo, sendo que, neste caso, a matriz H de transformação possui oito graus de liberdade, sendo necessário determinar a projeção dos quatro vértices e das bordas do módulo para realizar o ajuste. Um exemplo da aplicação do método para o segundo caso pode ser visto na Fig. 4.

São apresentadas na IEC TS 60904-13 (2018) soluções para o ajuste da luz difusa, onde é proposto a sobreposição das imagens em EL do módulo energizado e não energizado, com o intuito de realizar uma subtração de quadros. No processo de aquisição são obtidas imagens com bordas mais escuras (vinhetas) que podem interferir no reconhecimento de regiões defeituosas. Assim, estas áreas de borda precisam ser excluídas para que o programa forneça informações acuradas. Um dos métodos recomendados pela norma em questão consiste na obtenção de uma imagem da célula para determinar a extensão da vinheta e definir uma matriz de normalização. Ademais, é desejável um certo nível de nitidez das imagens exigindo uma otimização do foco. O operador Tenengrad pode realizar a convolução de imagens aplicando o filtro de Sobel e comparando o gradiente dos pixels vizinhos, mostrando-se um excelente recurso para o aperfeiçoamento da nitidez, como apresentado por Xia *et al.* (2016) e recomendado na IEC TS 60904-13 (2018).

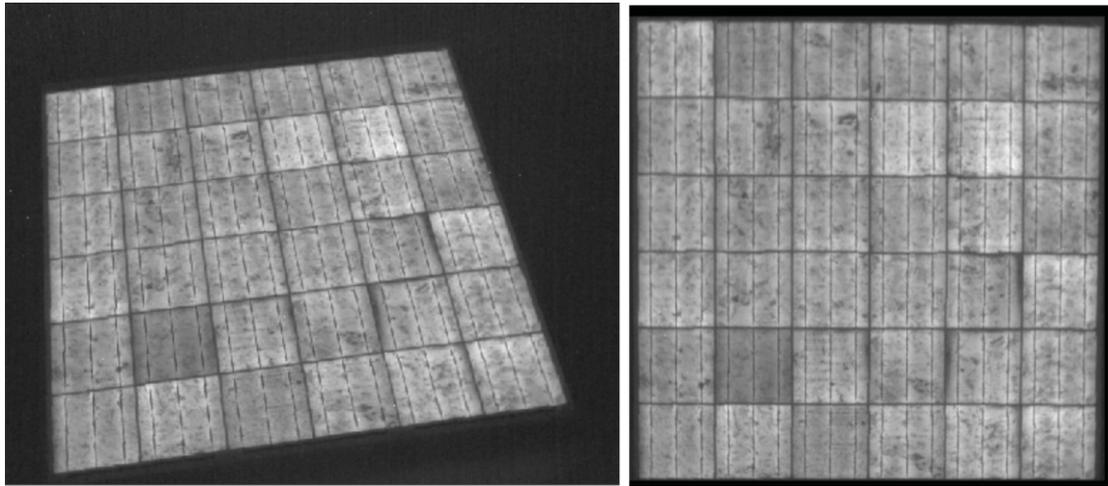


Figura 4 - Exemplo de perspectiva distorcida (esquerda) e perspectiva após a correção (direita).

Fonte: Mantel *et al.* (2018).

Existem diversos recursos disponíveis para aplicar as correções citadas assim como para realizar a análise das imagens através do aprendizado de máquina, tais como as ferramentas de processamento de imagens disponíveis no MATLAB e em bibliotecas como a *Python Image Library* (PIL), *OpenCV* e *Scikit-image*, que podem ser integradas com a biblioteca *Numpy* para otimizar o trabalho com as matrizes de pixels. Independente da ferramenta escolhida, é indispensável realizar o pré-processamento, tais como as etapas apresentadas no fluxograma da Fig. 5. Com as correções devidamente aplicadas, pode-se, por exemplo, analisar o histograma de intensidade eletroluminescente das imagens, com o intuito de detectar regiões de baixa intensidade onde a probabilidade de defeitos é maior.

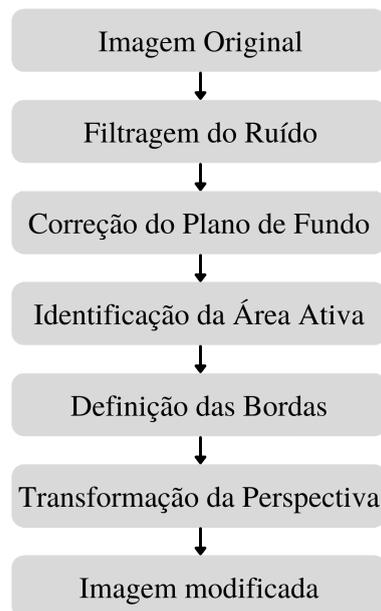


Figura 5 - Adaptado de IEA-PVPS T13-10:2018.

4. DETECÇÃO DE DEFEITOS

A análise de imagens EL de dispositivos FV é uma ferramenta importante na detecção e caracterização de defeitos de diversas naturezas (Fada *et al.*, 2017; Figueiredo *et al.*, 2019; Kaden *et al.*, 2015; Liu *et al.*, 2013; Martínez-Moreno *et al.*, 2013; Mchedlidze *et al.*, 2016; Peike *et al.*, 2014; Weber e Kutzer, 2009). Os padrões de defeitos podem ser percebidos de forma visual ao se comparar imagens de células e módulos íntegros do mesmo modelo com imagens de módulos e células afetados.

Por outro lado, automatizar o processo de análise de imagens EL de módulos FV e de detecção dos defeitos, além de acelerar a avaliação das imagens, contribui para tornar o método mais econômico, uma vez que o processo é qualitativo e envolve um grande número de imagens. Portanto, com as imagens devidamente tratadas e para executar uma estratégia de detecção otimizada, faz-se necessário a utilização de um método automático para identificação dos defeitos.

Takahashi *et al.* (2006) estabeleceu boa relação entre a distribuição da intensidade eletroluminescente e o mapeamento da distância de difusão de portadores minoritários em células de silício cristalino e policristalino. Propõe-se um método de varredura em dois eixos da emissão eletroluminescente para detectar defeitos, levando em consideração a variação natural que há na região dos *busbars* e dos *fingers*. Fuyuki e Kitiyanan (2009) lançaram mão da mesma técnica de varredura, com a adição de uma técnica de subtração de imagens de eletroluminescência em diferentes temperaturas, como o intuito de distinguir defeitos intrínsecos e extrínsecos em células de silício policristalino.

Conforme apresentado por Chian e Tian (2020), é possível detectar defeitos utilizando métodos de análise global e local, tal que os métodos locais comumente são mais eficientes na definição de defeitos específicos. Desse modo, com o intuito de reconhecer diferentes tipos de defeitos, precisa-se analisar o histograma de intensidade eletroluminescente individual de cada célula. Para isso podemos desmembrar a imagem do módulo, dividindo o número de pixels, em X e em Y, pelo número de células de cada dimensão, considerando que as imagens estejam alinhadas e com a perspectiva corrigida. Esse método, proposto na IEA-PVPS T13-10 (2018), mostra-se eficiente tendo em vista que a aplicação de algoritmos mais complexos nessas regiões reduzidas pode prejudicar a aquisição de informações. Um exemplo simples da distribuição da intensidade EL de um módulo FV sujeito ao ensaio de Degradação Induzida pelo Potencial (PID) é mostrado na Fig. 6.

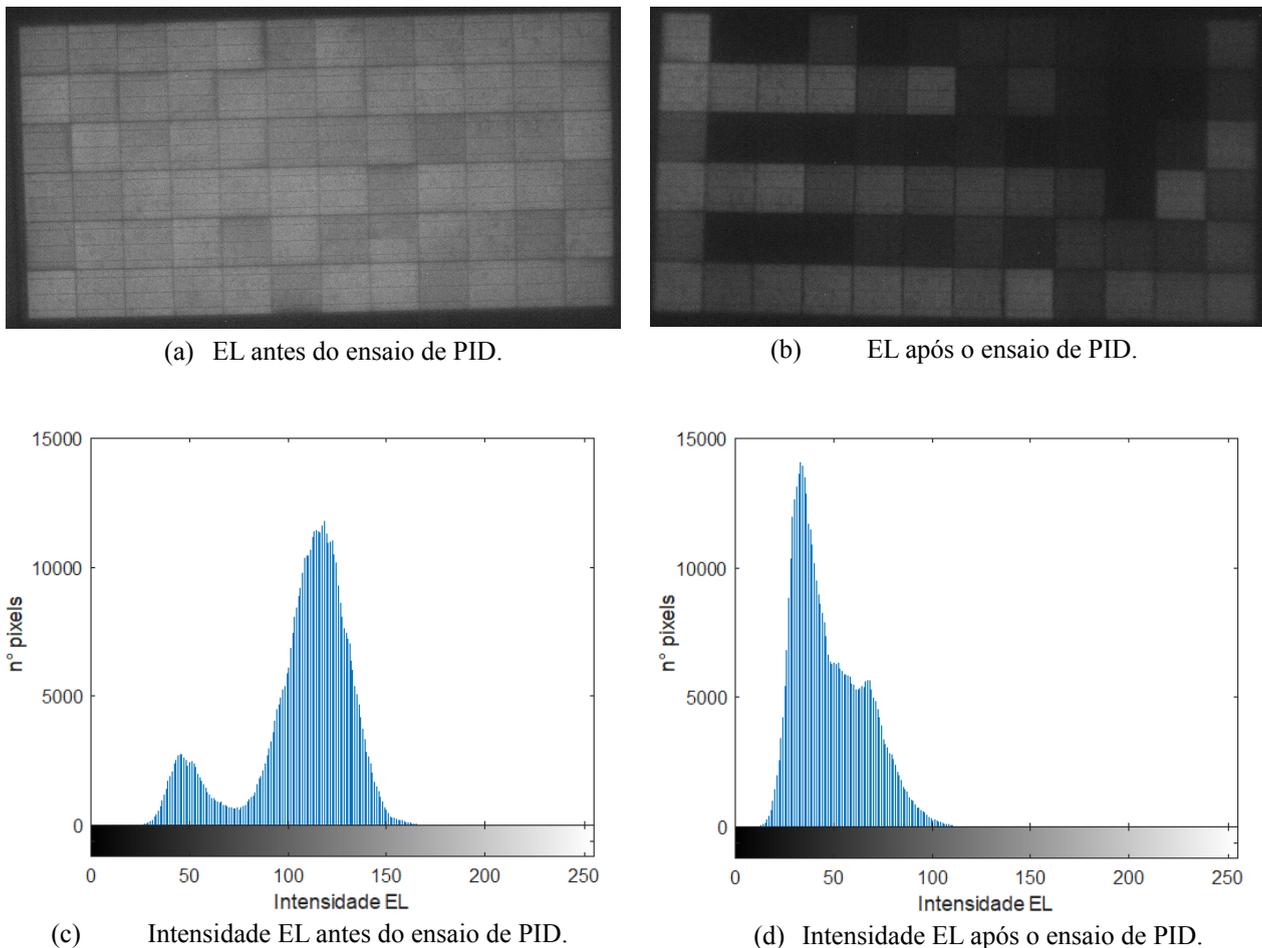


Figura 6 - Imagens em EL e histograma de intensidades de um módulo sob ensaio de PID.

Machine Learning (ML), ou aprendizado de máquina, é um ramo da inteligência artificial (IA) onde algoritmos captam dados e possuem a capacidade de interpretá-los para reconhecer padrões com o intuito de tomar decisões. Com o avanço da IA nos últimos anos, o ML tem sido proposto extensivamente para a detecção de defeitos em módulos fotovoltaicos (Tang *et al.*, 2020; Dhimish, 2021; Demirci *et al.*, 2021; Wang *et al.*, 2021). Nas técnicas de aprendizado

de máquina, conforme apresentado por Luo *et al.* (2019), o trabalho de detecção de defeitos é tratado como um problema de classificação binária, ou seja, com defeitos ou sem defeitos. Os métodos de ML podem ser subdivididos em supervisionados, não supervisionados, semi-supervisionados ou em aprendizagem por reforço, podendo ser aplicados para detectar o comportamento anômalo nos módulos e classificar os defeitos nas células degradadas (IEA-PVPS T13-10, 2018; Mellit e Kalogirou, 2021).

A aprendizagem supervisionada consiste na modelagem de uma distribuição de probabilidade condicional entre as imagens (representadas por matrizes de pixels) e os vetores de classificação binária (com defeito ou sem defeito) (Luo *et al.*, 2019), onde há dependência entre a entrada e a saída, de modo que o algoritmo pode estimar valores de saída de acordo com novos dados. Esse tipo de abordagem pode ser usada para resolver problemas de regressão e classificação (Mellit e Kalogirou, 2021). Alguns dos métodos desta classe são: Máquina de Vetores de Suporte (*Support Vectors Machine* - SVM), Árvores de Decisão e Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNN). A SVM é um método de reconhecimento de padrões, no entanto sua formulação original, proveniente da teoria de aprendizagem estatística criada por Vladimir Vapnik (Vapnik, 1999), não incorpora informações para classificação de imagens digitais. Dessa forma, Bovolo e Bruzzone (2006) propuseram uma técnica para considerar o contexto espacial dos pixels analisados utilizando as funções Kernel, com a finalidade de aumentar a robustez do procedimento de aprendizagem e diminuir a quantidade de erros discrepantes, e critérios de decisão baseados nos padrões das imediações dos pixels analisados para normalizar a classificação.

Se comparada a outras técnicas de aprendizado de máquina, a exatidão das redes neurais convolucionais geralmente é maior. Entretanto, as CNNs precisam de um grande banco de dados para o treinamento, o que exige uma alta capacidade computacional, demandando o uso de uma GPU para um menor tempo de processamento (Akram *et al.*, 2019). Esse método é baseado na estrutura do córtex visual presente no cérebro humano e, assim como a SVM, é projetado para reconhecer padrões e determinar novas informações a partir do conhecimento adquirido, sendo comumente aplicado na análise de imagens. A árvore de decisão, em contrapartida, é um método de aprendizagem de máquina preditivo que, a partir de um conjunto de dados fornecidos, realiza uma modelagem otimizada em uma estrutura com ramificações (árvore). A árvore possui nós de decisão, descritos por condições lógicas, e nós terminais, que representam os resultados da decisão. Assim, cada nó reflete uma certa característica e os ramos correspondem a uma faixa de valores de saída (Zao e Zhang, 2007). Apesar de ser de fácil compreensão por não exigir conhecimentos estatísticos, esse modelo é instável já que pequenas variações nos dados de treinamento podem gerar diversas outras ramificações, afetando as árvores descendentes.

Existe a possibilidade de utilizar a aprendizagem não supervisionada. Nesse modelo não há classificação prévia da saída, de modo que o algoritmo é treinado com dados não rotulados, procurando regras e padrões no conjunto de informações disponível para descrever os dados. A aprendizagem não supervisionada é usada, principalmente, para resolver problemas relacionados à *clustering* (agrupamento de dados) e associação (Mellit e Kalogirou, 2021). Esse tipo de abordagem é útil quando não há um grande número de amostras de imagens no banco de dados inicial. Assim, o modelo age elaborando grupos de teste semelhantes no conjunto de dados de entrada. Um exemplo dessa abordagem são as Redes Adversárias Generativas (*Generative Adversarial Network* - GANs), um tipo de arquitetura de CNN de aprendizagem profunda (*Deep Learning*). Nela existe uma rede neural geradora para criar novos dados e uma rede neural discriminadora para avaliar a autenticidade da informação, na qual há um loop onde as repetições auxiliam no aprendizado do algoritmo. Embora os métodos de aprendizagem não supervisionados sejam capazes de aprender com imagens não rotuladas, eles são mais suscetíveis a distorções (Luo *et al.*, 2019).

Diferente dos modelos supervisionados e não supervisionados, os métodos de aprendizagem por reforço realizam a detecção de defeitos de superfície com um conjunto de dados reduzido por meio de um sistema de recompensas e punição para otimizar os parâmetros internos automaticamente. No aprendizado por reforço, o sistema de inteligência artificial lida com um problema a partir de tentativa e erro para encontrar uma solução, sendo bastante utilizado para solucionar problemas de classificação e controle (Mellit e Kalogirou, 2021). Para que o computador siga o caminho desejado, a IA recebe recompensas ou penalidades pelas ações executadas, com o objetivo de maximizar a recompensa.

Já na aprendizagem semi-supervisionada, o algoritmo recebe informações pré-definidas e dados não classificados, sendo treinado para encontrar um modelo. Os principais tipos de problemas resolvidos com este tipo de aprendizagem são a classificação e o *clustering*. Um resumo dos principais métodos de ML e suas respectivas funções é apresentado na Fig. 7.

5. CONCLUSÕES

Devido à eficiência de predição e reconhecimento de defeitos em tempo hábil, os métodos de ML têm crescido cada vez mais no setor em questão, apresentando resultados altamente precisos. Como apresentado por Mellit e Kalogirou (2021), as abordagens semi-supervisionadas e de aprendizagem por reforço raramente são utilizadas para detecção de defeitos em módulos fotovoltaicos. Com a modelagem supervisionada, as respostas obtidas a partir do conjunto de treinamento são conhecidas e a precisão do modelo pode ser determinada com exatidão. Desse modo, esse modelo vem sendo aplicado com maior frequência no campo de estudo em pauta. A aprendizagem não supervisionada

também tem seu espaço e a melhor metodologia a ser utilizada vai depender de fatores como custo computacional, facilidade de implementação, tamanho e robustez do banco de dados.

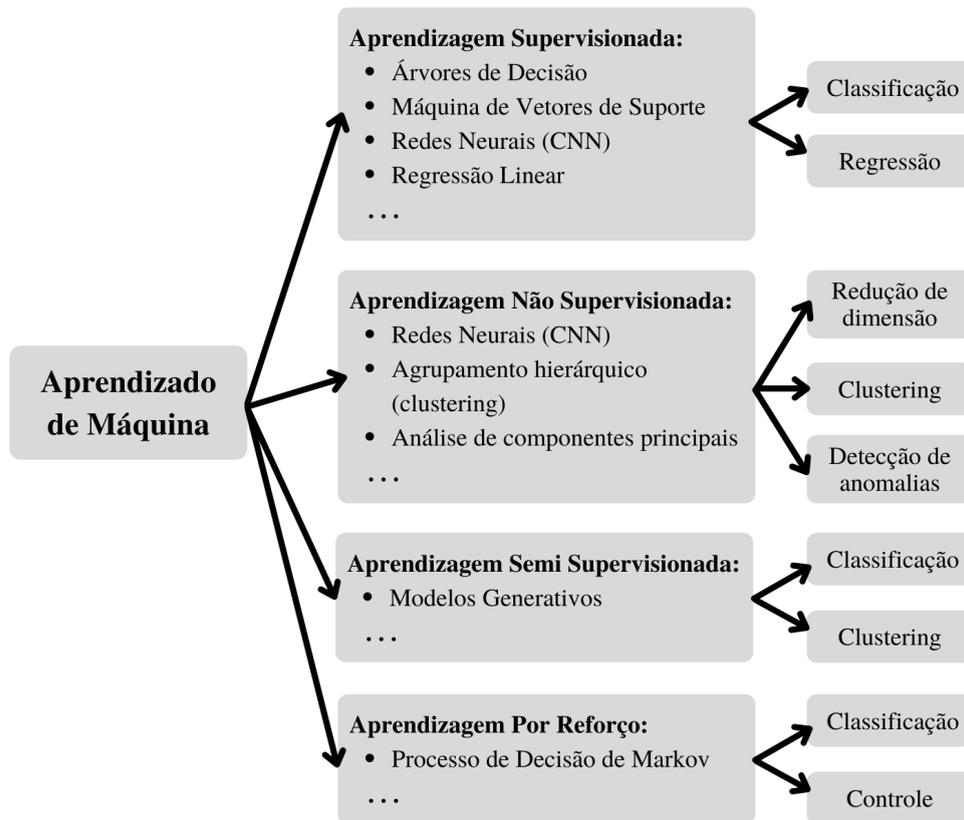


Figura 7 - Principais algoritmos de ML e suas aplicações.
(Adaptado de Mellit e Kalogirou, 2021).

Para reconhecer padrões nas imagens é necessário que elas possuam um formato adequado para o processamento. O tempo necessário para obtenção de uma imagem em EL com boa qualidade de um módulo FV muitas vezes é um fator limitante para a aplicação dos métodos para detecção de defeitos em grande escala, tendo em vista a demanda de ajustes de acordo com cada equipamento, como a adequação do foco da câmera, o tempo de exposição, etc. Para aproveitar o máximo de imagens obtidas, sem perder a qualidade dos resultados, foram apresentados alguns procedimentos a serem aplicados para a correção de vinhetas, perspectiva, nitidez, e de outros fatores necessários para melhoria das imagens.

Agradecimentos

Este trabalho tem o suporte da Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) por meio do Programa de Bolsa de Iniciação Científica. Os autores agradecem à FAPERJ pelo apoio dado no desenvolvimento das pesquisas.

REFERÊNCIAS

- Akram, M. W., Li, G., Jin, Y., Chen, X., Zhu, C., Zhao, X., Khaliq, A., Faheem, M., Ahmad, A., 2019. CNN based automatic detection of photovoltaic cell defects in electroluminescence images, *Energy*, vol. 189, Artigo 116319.
- Bovolo, F., Bruzzone, L., Marconcini, M., 2006. A Novel Context-Sensitive SVM for Classification of Remote Sensing Images, *IEEE International Symposium on Geoscience and Remote Sensing*, pp. 2498-2501.
- Chian, Y., Tian, J., 2021. Surface Defect Inspection in Images Using Statistical Patches Fusion and Deeply Learned Features, *AI*, 2, n. 1, pp. 17 - 31.
- Demirci, M., Y., Bešli, N., Gümüşçü, A., 2021. Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in Electroluminescence images, *Expert Systems with Applications*, vol. 175, 114810, ISSN 0957-4174.

- Dhimish, M., 2021. Defining the best-fit machine learning classifier to early diagnose photovoltaic solar cells hot-spots, *Case Studies in Thermal Engineering*, vol. 25, Artigo 100980.
- Fada, J. S., Hossain, M. A., Braid, J. L., Yang, S., Peshek, T. J., French, R. H., 2017. Electroluminescent Image Processing and Cell Degradation Type Classification via Computer Vision and Statistical Learning Methodologies, *IEEE 44th Photovoltaic Specialist Conference (PVSC)*, Washington, DC, pp. 3456 - 3461.
- Figueiredo, G., Almeida, M. P., Manito, A., Zilles, R., 2018. Alternativa de Baixo Custo para Imagens em Eletroluminescência de Módulos Fotovoltaicos. *VII Congresso Brasileiro de Energia Solar*, Gramado.
- Figueiredo, G., Almeida, M. P., Manito, A. R. A., Zilles, R., 2019. Assessment of an early degraded PV generator. *Solar Energy*, vol. 189, pp. 385 – 388.
- Fuyuki, T., Kitiyanan, A., 2009. Photographic diagnosis of crystalline silicon solar cells utilizing electroluminescence, *Applied Physics A*, vol. 96, pp. 89 – 196.
- Fuyuki, T., Kondo, H., Yamazaki, T., Takahashi, Y., Uraoka, Y., 2005. Photographic surveying of minority carrier diffusion length in polycrystalline silicon solar cells by electroluminescence, *Applied Physics Letters*, vol. 86, n. 26, pp. 1 - 3.
- IEC TS 60904-13, 2018. Photovoltaic Devices Part 13: electroluminescence of photovoltaic modules, vol. 1.
- International Energy Agency, 2018. Report IEA-PVPS T13-10: Review on infrared and electroluminescence imaging for PV field applications.
- Kaden, T., Lammers, K., Möller, H. J., 2015. Power loss prognosis from thermographic images of PID affected silicon solar modules, *Solar Energy Materials and Solar Cells*, vol. 142, pp. 24-28.
- Köntges, M., Siebert, M., Hinken, D., 2009. Quantitative analysis of PV-modules by electroluminescence images for quality control, *24th European Photovoltaic Solar Energy Conference*, Hamburgo.
- Liu, H., Huang, C., Lee, W., Lin, M., 2013. High Voltage Stress Impact on P Type Crystalline Silicon PV Module., *Energy and Power Engineering*, vol. 5, pp. 455-458.
- Luo, Q., Fang, X., Liu, L., Yang, C., Sun, Y., 2020. Automated Visual Defect Detection for Flat Steel Surface: A Survey, *IEEE Transactions on Instrumentation and Measurement*, vol. 69, n. 3, pp. 626 - 644.
- Mantel, C., Spataru, S., Parikh, H., Sera, D., Benatto, G., Riedel, N., Thorsteinsson, S., Poulsen, B., Forchhammer, S., 2018. Correcting for Perspective Distortion in Electroluminescence Images of Photovoltaic Panels, *IEEE 7th World Conference on Photovoltaic Energy Conversion*, pp. 0433-0437.
- Martínez-Moreno, F., Figueiredo, G., Lorenzo, E., 2018. In-the-field PID related experiences, *Solar Energy Materials and Solar Cells*, vol. 174, pp. 485 - 493.
- Mchedlidze, T., Herguth, A., Weber, J., 2016. Monitoring of Si-solar cell degradation with electroluminescence, *Solar Energy Materials and Solar Cells*, vol. 155, pp. 38 – 42.
- Mellit, A., Kalogirou, S., 2021. Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions, *Renewable and Sustainable Energy Reviews*, vol. 143, Artigo 110889.
- Peike, C., Hoffmann, S., Dürr, I., Weiß, K.-A., Bogdanski, N., Köhl, M., 2014. PV module degradation in the field and in the lab - how does it fit together ?, *29th European PV Solar Energy Conference and Exhibition*, Amsterdam, pp. 3110 - 3114.
- Petraglia, A., Nardone, V., 2011. Electroluminescence in photovoltaic cell. *Physics Education*, [s.l.], vol. 46, n. 5, pp. 511–513.
- Takahashi, Y., Kaji, Y., Ogane, A., Uraoka, Y., Fuyuki, T., 2006. -"Luminoscopy"-Novel Tool for the Diagnosis of Crystalline Silicon solar cells and Modules Utilizing Electroluminescence, *IEEE 4th World Conference on Photovoltaic Energy Conference*, Waikoloa, HI, USA.
- Tang, W., Yang, Q., Xiong, K., Yan, W., 2020. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images, *Solar Energy*, vol. 201, pp. 453 - 460.
- Vapnik, V., 1999, An Overview of Statistical Learning Theory, *IEEE Transactions On Neural Networks*, vol. 10, n. 5, pp. 988 - 999.
- Wang, Y., Li, L., Sun, Y., Xu, J, Jia, Y., Hong, J., Hu, X., Weng, G., Luo, X., Chen, S., Zhu, Z., Chu, J., Akiyama, H., 2021, Adaptive automatic solar cell defect detection and classification based on absolute electroluminescence imaging, *Energy*, vol. 229, Artigo 120606.
- Weber, T., Kutzer, M., 2009. Dark IV Curve Analysis of Single Solar Cells in Photovoltaic Modules Using Electroluminescence Imaging, *24th European Photovoltaic Solar Energy Conference*, Hamburg.
- Xia, X., Yao, Y., Liang, J., Fang, S., Yang, Z. Cui, D., 2016. Evaluation of focus measures for the autofocus of line scan cameras, *Optik*, vol. 127, pp. 7762 - 7775.
- Zhao, Y., Zhang, Y., 2008. Comparison of decision tree methods for finding active objects, *Advances in Space Research*, vol. 41, Issue 12, pp. 1955-1959.

STRATEGIES FOR THE ANALYSIS OF THE ELECTROLUMINESCENCE EMISSION OF PHOTOVOLTAIC MODULES

***Abstract.** A literature review is presented addressing the major characteristics to assess photovoltaic modules electroluminescent emission in order to detect defects as a complementation of the traditional photovoltaic characterization methods. General aspects are presented regarding the image acquisition and the methods for pre-processing are mentioned. A review of the works on the subject of defect detection shows a strong tendency for automatic processing and the development and application of artificial intelligence techniques. Machine learning methods are a promising alternative in terms of computational requirements and assertivity on the detection.*

Key words: *Electroluminescence, Photovoltaic Module, Machine Learning.*