CLASSIFICAÇÃO DE FALHAS TÉRMICAS EM MÓDULOS FOTOVOLTAICOS UTILIZANDO REDES NEURAIS CONVOLUCIONAIS

Guilherme Gabriel Saldanha Pereira[1], Rosana C. B. Rego[2]

[1] *Bacharelado em Engenharia de Computação, Universidade Federal Rural do Semi-Árido, Rio Grande do Norte, Brasil (guilherme.pereira@alunos.ufersa.edu.br)*
[2] *Departamento de Engenharias e Tecnologia, Universidade Federal Rural do Semi-Árido, Rio Grande do Norte, Brasil*

Resumo: Este trabalho propõe uma CNN simples para identificar falhas térmicas em módulos fotovoltaicos por imagens infravermelhas obtidas por drones. O modelo foi comparado às arquiteturas ResNet50 e VGG16. Apesar das altas acurácias, o *Recall* evidenciou a escassez de dados reais de falhas. Os mapas de relevância mostraram que a rede aprendeu padrões térmicos, mas apresentou falsos negativos em pontos quentes isolados. A CNN simples mostrou-se mais adequada para pequenos conjuntos de dados.

Palavras-chave: Aprendizado de Máquina; Redes Neurais Convolucionais; Painéis Fotovoltaicos; Termografia

INTRODUÇÃO

Os sistemas fotovoltaicos são constituídos por equipamentos expostos continuamente à radiação solar para a geração de energia elétrica. Contudo, esses sistemas estão submetidos a diversos fatores que contribuem diretamente para a degradação e o desgaste dos módulos, tais como ruídos da rede elétrica, falhas na instalação dos componentes e o envelhecimento natural decorrente do tempo de operação.

De acordo com o relatório da *International Energy Agency Photovoltaic Power Systems Programme* (IEA-PVPS) (KÖNTGES et al., 2014), é possível identificar módulos defeituosos por meio do surgimento de *hot spots* (pontos quentes ou falhas térmicas). Essas regiões apresentam temperaturas significativamente superiores à de operação normal, o que impacta diretamente na redução da potência gerada e, a longo prazo, compromete a vida útil do equipamento devido ao estresse térmico severo.

Um método de manutenção preventiva para mitigar este problema consiste em identificar a ocorrência de *hot spots* nos módulos utilizando imagens termográficas obtidas durante inspeções de campo. Conforme revisado pela IEA-PVPS (JAHN et al., 2018), essa identificação pode ser otimizada por meio de câmeras com sensores infravermelhos acopladas a veículos aéreos não tripulados (*drones*), permitindo localizar manchas de calor indicativas de falhas de maneira rápida e precisa.

Este trabalho propõe o uso de um modelo de rede neural convolucional (*Convolutional Neural Network*: CNN) (HAYKIN, 2001) para identificar módulos defeituosos a partir de imagens térmicas que capturam múltiplos painéis de um sistema fotovoltaico. O objetivo é permitir que o modelo aprenda os padrões visuais das imagens e consiga distinguir quais módulos possuem anomalias térmicas significativas o suficiente para serem classificados como defeituosos ou normais a partir da identificação dos *hot spots*.

O *dataset* utilizado para o treinamento e avaliação do modelo será o *Photovoltaic system thermography* (GABRIEL, 2024). Este conjunto de dados é dividido em duas partes: o *dataset_1*, que será empregado no desenvolvimento do modelo (dividido entre as etapas de treino, teste e validação), e o *dataset_2*, utilizado exclusivamente para uma validação em cenário prático através de uma *dashboard* interativa projetada para identificar a quantidade total de módulos da imagem e exibir aqueles que são defeituosos.

Portanto, o objetivo deste trabalho é desenvolver um modelo de CNN para a classificação de falhas térmicas em módulos fotovoltaicos utilizando imagens infravermelhas, comparando seu desempenho com arquiteturas pré-treinadas, tais como ResNet (Residual Network) e VGG (Visual Geometry Group), e avaliando sua aplicabilidade em um cenário real de inspeção de sistemas fotovoltaicos.

O trabalho está estruturado da seguinte forma: a seção 2 apresenta o material e os métodos utilizados, detalhando o processo de pré-processamento das imagens, a arquitetura da CNN proposta, as técnicas de otimização e a comparação com outros modelos. A seção 3 discute os resultados obtidos, analisando as curvas de erro, as matrizes de confusão e as contribuições dos pixels para a classificação. Por fim, a seção 4 conclui o trabalho e sugere direções para pesquisas futuras.

MATERIAL E MÉTODOS

O fluxo de desenvolvimento do trabalho foi dividido em fases que apontam as principais etapas, as quais podem ser observadas na Figura 1.

Os dados exportados do *dataset_1* passaram inicialmente por uma varredura para identificar as princi-

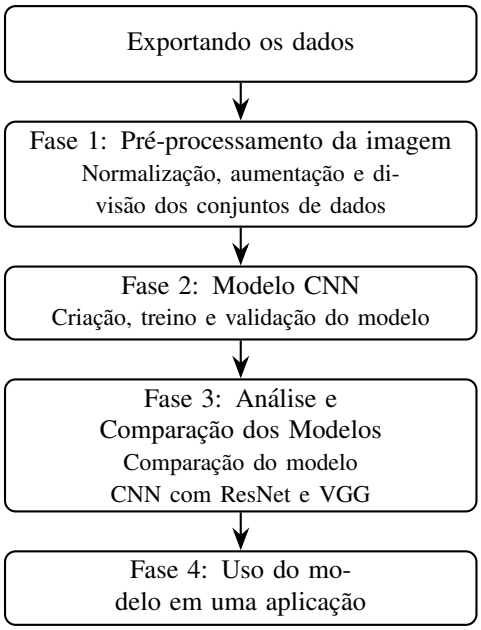


Figura 1: Fluxo de trabalho da CNN própria.

pais características das imagens. As imagens são termográficas, ou seja, capturam a radiação infravermelha emitida pelos objetos, o que permite identificar variações de temperatura, elas são compostas por 3 canais de cores (RGB) com altura de 512 pixels e largura de 640 pixels, e a intensidade dos canais varia entre 0 e 255. A Figura 2 ilustra um exemplo de uma das imagens dentre as 120 que compõem o *dataset_1*.

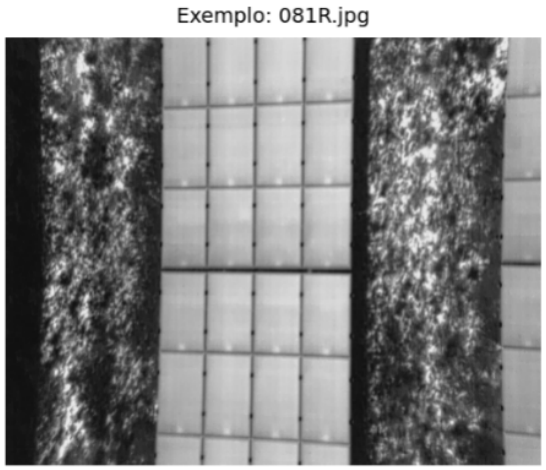


Figura 2: Exemplo das imagens obtidas no *dataset_1*.

A Fase 1 foi iniciada com o objetivo de segmentar individualmente cada módulo fotovoltaico a partir das imagens completas dos painéis. Para viabilizar este processo, foram utilizados os arquivos JSON existentes no próprio *dataset* e que contêm as anotações específicas de cada imagem. Essas anotações compreendem as especificações geométricas de cada um dos módulos visíveis, mapeando seus quatro cantos e o ponto central em um plano cartesiano (x, y). Ademais, os metadados associados carregam os respectivos rótulos de cada unidade, indicando se o módulo é ou não defeituoso.

Com o objetivo de preparar os dados para o treinamento do modelo, as imagens passaram por uma sequência de etapas de tratamento digital. Foi realizado o recorte espacial de cada módulo, seguido por um redimensionamento para uma resolução fixa e, por fim, a normalização dos valores dos pixels. O redimensionamento foi realizado para a resolução de 64×64 pixels.

A distribuição inicial do conjunto de dados seguiu a proporção de 60% para treino, 20% para teste e 20% para validação, conforme as práticas recomendadas na literatura de aprendizado de máquina. Entretanto, pelo fato de a maioria dos rótulos originais do *dataset_1* serem de módulos não defeituosos, tornou-se necessária a geração de novas amostras utilizando a técnica de aumentação de dados para balancear a classe minoritária (defeituosos). Aplicou-se rotações, translações e ruídos para criar variações das imagens dos módulos defeituosos no conjunto de treino.

A partir da Fase 1, foi possível realizar o recorte espacial de cada um dos módulos contidos nas 120 imagens do *dataset_1*. Foi identificado um total de 4107 unidades fotovoltaicas e, dentre elas, 4081 foram rotuladas como não defeituosas (representando 99.4% do total) e apenas 26 unidades foram rotuladas como defeituosas (representando 0.6%).

A Figura 3 apresenta um comparativo entre as imagens dos módulos originais e os que foram aumentados.

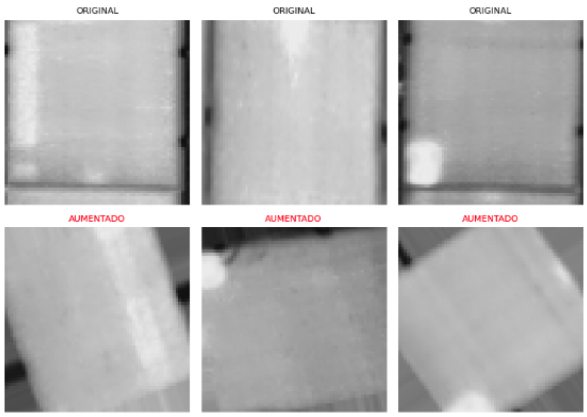


Figura 3: Comparação dos módulos defeituosos originais com os aumentados.

Arquitetura da Rede Neural Convolucional Proposta

Seguindo para a Fase 2, a Figura 4 ilustra a arquitetura completa do modelo CNN proposto para a classificação binária dos módulos. Além da disposição das camadas estruturais, mecanismos de otimização adicionais foram inseridos e são detalhados a seguir.

A arquitetura proposta utiliza blocos convolucionais empilhados para extrair progressivamente características térmicas das imagens infravermelhas, identificando padrões associados a *hot spots*. Cada bloco combina camadas convolucionais com filtros (3 $\times$

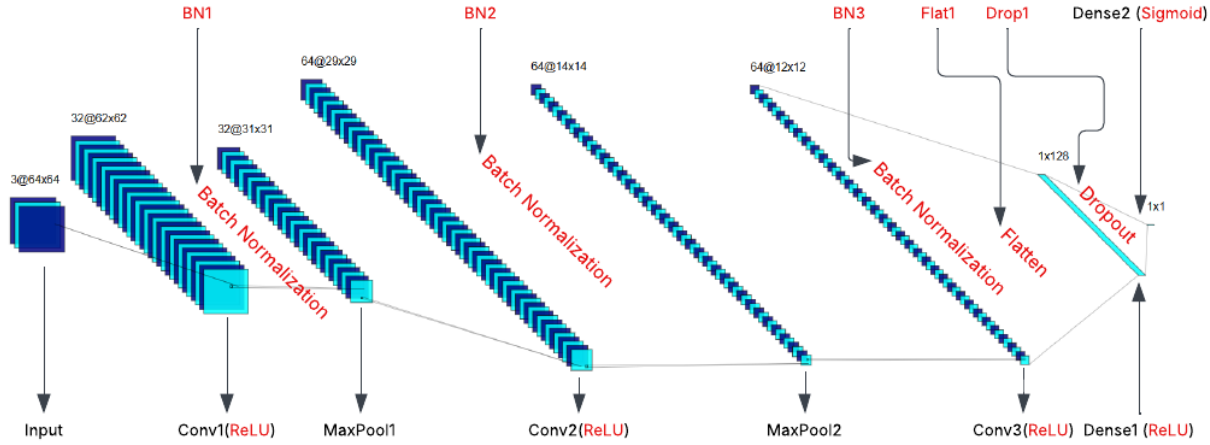


Figura 4: Arquitetura da CNN construída.

3), ativação ReLU e *Max-Pooling*, reduzindo dimensionalidade e custo computacional enquanto preserva informações relevantes. Em seguida, a operação *Flatten* converte os mapas de características em um vetor unidimensional, alimentando um classificador MLP composto por uma camada densa de 128 neurônios e uma saída sigmoide para classificação binária da presença de anomalias térmicas. Para melhorar a generalização e estabilidade do treinamento, foram aplicadas técnicas de regularização e otimização, como *Early Stopping*, *Reduce LR on Plateau* e *Dropout* de 0.2.

ResNet50 e VGG16 para comparação

As redes ResNet50 e VGG16 foram escolhidas para comparação por serem arquiteturas pré-treinadas amplamente utilizadas na literatura para tarefas de classificação de imagens, incluindo a detecção de falhas em sistemas fotovoltaicos. Por exemplo, Açikgöz, Korkmaz e Dandil (HAIDARI et al., 2022) realizaram uma comparação direta entre a ResNet50 e outros modelos, como SqueezeNet, GoogLeNet e VGG. Dentre as arquiteturas avaliadas pelos autores, a ResNet50 apresentou ótimos resultados, alcançando o maior F1-score entre as demais, com 85,37%. Já Cardinale-Villalobos et al. (CARDINALE-VILLALOBOS et al., 2023) propuseram o uso da ResNet na predição de *hot spots* de sistemas fotovoltaicos utilizando um sistema baseado em internet das coisas (*IoT*).

Dunderdale et al. (DUNDERDALE et al., 2020) demonstram a eficácia dessa arquitetura pré-treinada para a classificação de módulos defeituosos a partir de imagens térmicas infravermelhas, utilizando técnicas de *fine tunning* para o retreino do modelo. Outros trabalhos recentes, como Sashika (SASHIKA, 2026), também exploram técnicas de aprendizado de máquina para detecção de anomalias em células fotovoltaicas.

Vale mencionar que, neste trabalho, nenhum desses modelos passou por uma etapa de *fine tunning*. Além disso, eles foram utilizados com a mesma configuração de entrada da CNN própria, para fins comparativos entre as arquiteturas.

RESULTADOS E DISCUSSÃO

As simulações foram realizadas utilizando a biblioteca *TensorFlow* e a linguagem de programação *Python*. O ambiente de desenvolvimento integrado utilizado foi o *Google Colab*. A avaliação dos resultados foi realizada por meio da análise das curvas de erro de treino e validação, das matrizes de confusão e das métricas extraídas de cada um dos modelos. Além disso, foram extraídas as contribuições de cada pixel para a classificação utilizando o método de *SHAP*.

As Figuras 5, 6 e 7 mostram as curvas de erro de treino e validação para os modelos de CNN simples, ResNet50 e VGG16, respectivamente.

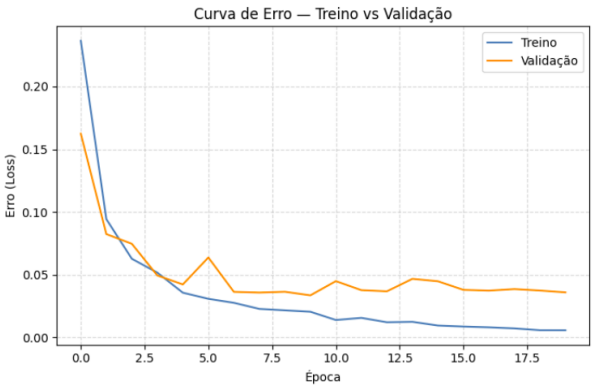


Figura 5: Curva de Erro da CNN.

A análise das curvas de perda de treinamento e validação evidenciou que as três arquiteturas convergiram para valores próximos de zero. Dentre os modelos avaliados, a CNN proposta apresentou a curva de perda de treinamento mais próxima de zero e alcançou convergência em um número reduzido de épocas. Entretanto, nas etapas finais do treinamento, observou-se a presença de oscilações na curva de validação, caracterizando indícios de sobreajuste e menor estabilidade na

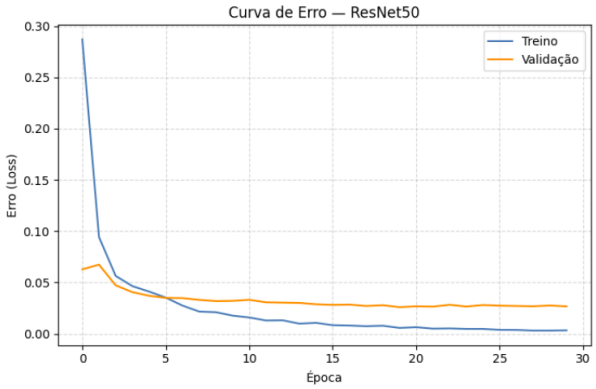


Figura 6: Curva de Erro da ResNet50.

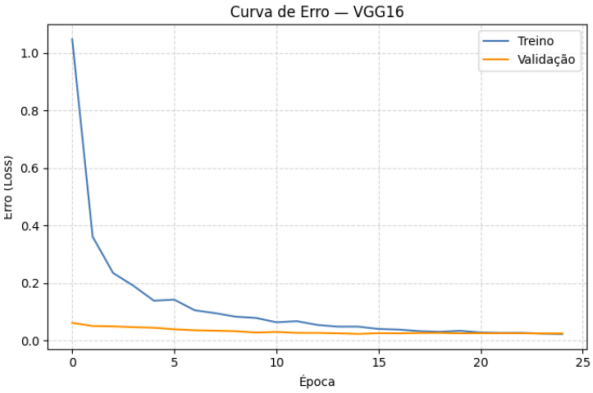


Figura 7: Curva de Erro da VGG16.

capacidade de generalização. Embora todas as arquiteturas tenham apresentado pequenos níveis de sobreajuste, a VGG16 destacou-se por exibir o comportamento mais estável entre as curvas de treinamento e validação, sugerindo melhor regularização do processo de aprendizado.

As matrizes de confusão dos modelos são apresentadas nas Figuras 8, 9 e 10. As matrizes de confusão mostram que os três modelos apresentaram alto número de classificações corretas para a classe Normal, enquanto a detecção da classe Defeituoso apresentou limitações devido à ocorrência de falsos negativos. A CNN proposta identificou corretamente dois módulos defeituosos, já a ResNet50 e VGG16 identificaram apenas um caso cada. Os resultados indicam que a elevada acurácia global foi influenciada pelo desbalanceamento entre as classes nos dados de teste, enquanto o *Recall* evidenciou maior sensibilidade à baixa quantidade de amostras reais de falha disponíveis no conjunto de teste.

A Figura 11 mostra o comparativo das métricas de cada modelo. A comparação das métricas mostra que a CNN proposta apresentou os maiores valores de *F1-Score*, precisão e *Recall* entre os modelos avaliados, indicando maior capacidade de identificar módulos defeituosos. ResNet50 e VGG16 obtiveram valores inferiores principalmente em *Recall*, refletindo maior ocorrência de falsos negativos. Apesar disso, os três modelos alcançaram acurácia próxima de 100%, evidenciando que essa métrica foi influenciada pelo desbalanceamento entre as classes, com predominância de amostras normais no conjunto de teste.

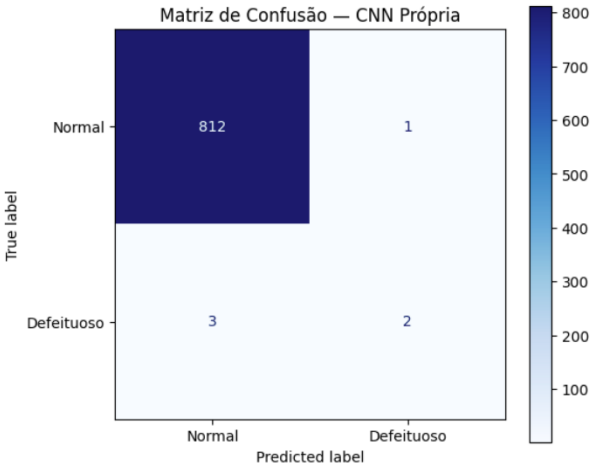


Figura 8: Matriz Confusão da CNN.

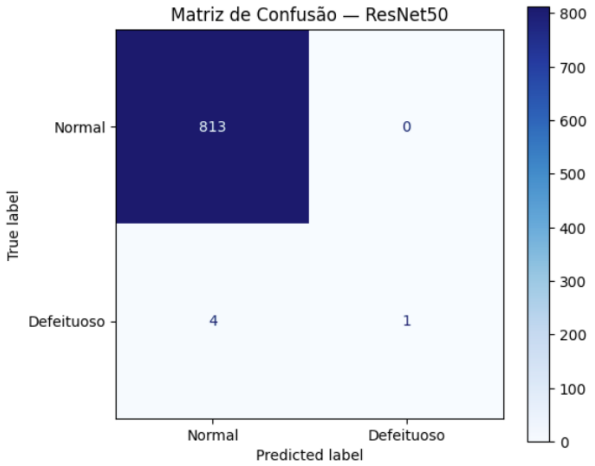


Figura 9: Matriz Confusão da ResNet50.

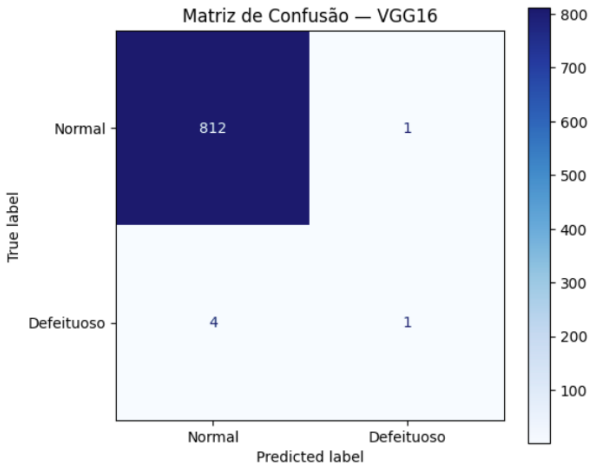


Figura 10: Matriz Confusão da VGG16.

Contribuições de cada Pixel para a Classificação

A utilização de *SHAP values* permite identificar a contribuição de cada *pixel* na decisão do modelo CNN, gerando mapas de relevância que destacam as regiões mais influentes para a classificação dos módulos.

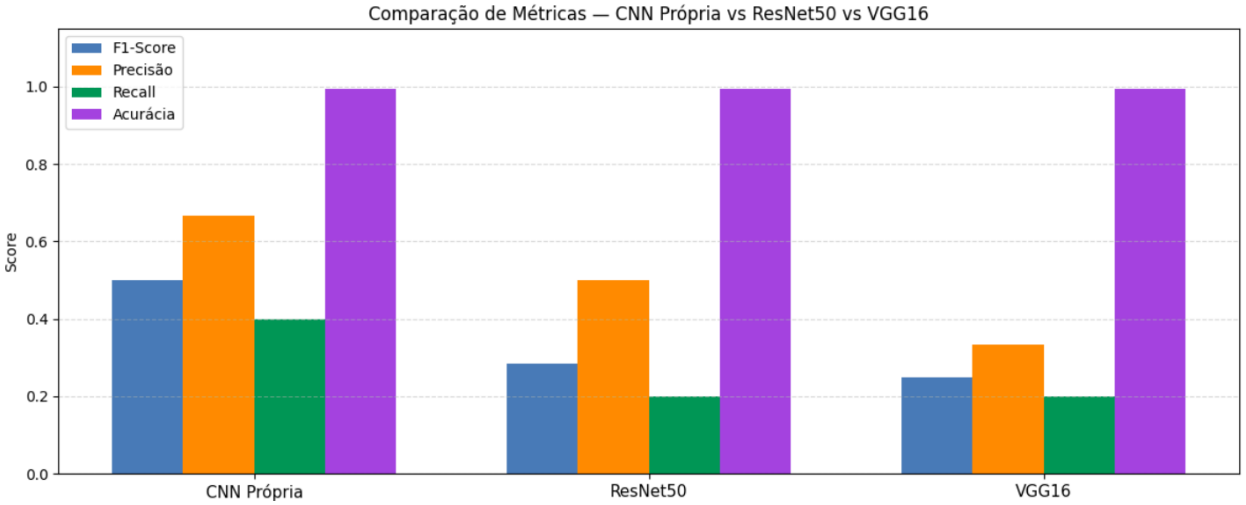


Figura 11: Comparação de Métricas das arquiteturas CNN, ResNet50 e VGG16.

Os *pixels* em vermelho indicam contribuição para a classe "Defeituoso", enquanto os azuis contribuem para a classe "Normal". Para exemplificar um caso de classificação correta, analisou-se o módulo apresentado na Figura 12, classificado com 98% de probabilidade de defeito. A imagem termográfica apresenta uma região de maior intensidade térmica no lado esquerdo do módulo, caracterizando um *hot spot*.

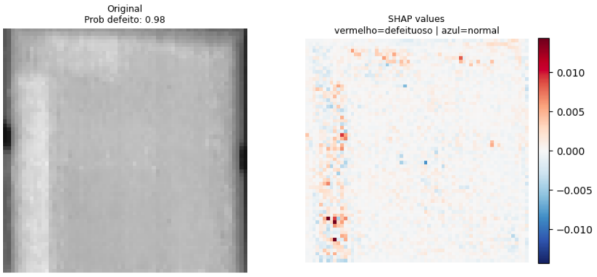


Figura 12: Exemplo que o modelo CNN próprio acerta a predição.

Para exemplificar o cenário de predição onde o modelo erra um módulo defeituoso, foi analisado o módulo ilustrado pela Figura 13, onde o modelo classificou esse módulo com 4% de probabilidade de ser defeituoso, embora a imagem claramente apresente o evento de *hot spot*.

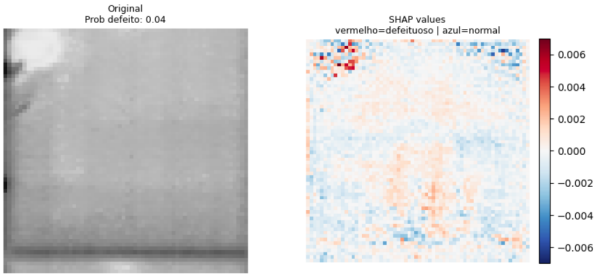


Figura 13: Exemplo que o modelo CNN próprio erra a predição.

A análise dos casos de acerto e erro mostrou que a CNN aprendeu a associar regiões de maior intensidade térmica aos padrões de *hot spots* presentes nas imagens infravermelhas. Entretanto, o modelo também passou a priorizar áreas extensas com *pixels* de menor intensidade térmica, reduzindo a influência de regiões isoladas de calor elevado na decisão final. Como consequência, alguns módulos contendo *hot spots* localizados foram classificados como normais, caracterizando casos de falsos negativos durante a predição.

Dashboard interativa

Após as análises realizadas na Fase 3, foi possível comparar os resultados dos modelos e escolher o melhor modelo para a aplicação prática. Uma dashboard interativa foi desenvolvida utilizando a biblioteca Streamlit (Streamlit, 2026) para a visualização dos sistemas fotovoltaicos, indicando os módulos que estão defeituosos ou não, juntamente com a quantidade de módulos detectados pelo arquivo JSON de anotação. A Figura 14 apresenta a interface da dashboard criada para o modelo CNN. Na dashboard, as imagens termográficas dos painéis fotovoltaicos são classificadas como defeituosos ou normais.

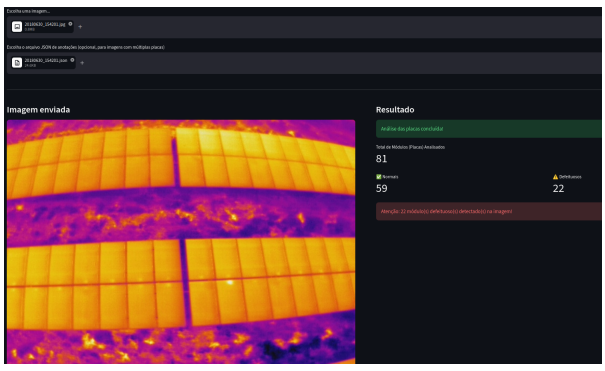


Figura 14: Dashboard criada para o modelo CNN.

CONCLUSÃO

Conclui-se que o modelo proposto apresentou limitações de desempenho associadas principalmente à reduzida quantidade de dados disponíveis para treinamento e validação. Embora a base de dados contivesse 4107 módulos fotovoltaicos, apenas 26 amostras foram rotuladas como defeituosas, e o conjunto de teste permaneceu com somente cinco casos reais de falha, mesmo após a aplicação de *data augmentation*. Esse desbalanceamento comprometeu a robustez estatística das métricas, uma vez que cada erro na classe Defeituoso produziu variações significativas no *Recall*. Como trabalhos futuros, sugere-se a unificação dos *datasets* 1 e 2 para ampliar o número de exemplos reais de falha, além da aplicação de *fine-tuning* nas arquiteturas ResNet50 e VGG16 para novas comparações. Também são recomendados ajustes de hiperparâmetros, como taxa de aprendizagem, número de neurônios e dimensões dos filtros convolucionais.

REFERÊNCIAS

CARDINALE-VILLALOBOS, L. et al. Iot system based on artificial intelligence for hot spot detection in photovoltaic modules for a wide range of irradiances. *Sensors*, MDPI, v. 23, n. 15, p. 6749, 2023.

DUNDERDALE, C. et al. Photovoltaic defect classification through thermal infrared imaging using a machine learning approach. *Progress in Photovoltaics: Research and Applications*, Wiley Online Library, v. 28, n. 3, p. 177–188, 2020.

GABRIEL, M. *Photovoltaic system thermography*. 2024. Kaggle. Disponível em: ⟨https://www.kaggle.com/datasets/marcosgabriel/photovoltaic-system-thermography⟩. Acesso em: 16 mai. 2026.

HAIDARI, P. et al. Deep learning-based model for fault classification in solar modules using infrared images. *Sustainable Energy Technologies and Assessments*, v. 52, p. 102110, 2022. ISSN 2213-1388. Disponível em: ⟨https://www.sciencedirect.com/science/article/pii/S221313882200162X⟩.

HAYKIN, S. *Redes neurais: princípios e práticas*. 2. ed. Porto Alegre: Bookman, 2001.

JAHN, U. et al. Review on ir and el imaging for pv field applications. *IEA-PVPS Task*, v. 13, 2018.

KÖNTGES, M. et al. Review of failures of photovoltaic modules. IEA International Energy Agency, 2014.

SASHIKA, R. E. *UEA MSc: Anomaly Detection in Photovoltaic Cell*. 2026. Kaggle. Disponível em: ⟨https://www.kaggle.com/code/rhedsonesashika/uea-msc-anomaly-detection-in-photovoltaic-cell⟩. Acesso em: 19 mai. 2026.

Streamlit. *Streamlit documentation*. 2026. Disponível em: ⟨https://docs.streamlit.io/⟩. Acesso em: 23 mai. 2026.