

Classificação de Inconformidades em Painéis Fotovoltaicos usando Processamento de Imagens e Redes Neurais Convolucionais^{*}

Rodrigo P. Ramos^{*} Ricardo M. Prates^{*} Jadsonlee da S. Sá^{**}
Adeon C. Pinto^{*} Eubis P. Machado^{*} Wêdson P. da Silva^{*}
José Bione M. Filho^{***} Alcides Codeceira Neto^{***} Alex C. Pereira^{***}
Eduardo B. Jatobá^{***}

^{*} Colegiado de Engenharia Elétrica - CENEL, Universidade Federal do Vale do São Francisco - Univasf, PE, (e-mail: rodrigo.ramos,ricardo.prates,adeon.pinto,eubis.machado,wedson.silva@univasf.edu.br).

^{**} Colegiado de Engenharia da Computação, Universidade Federal do Vale do São Francisco - Univasf, PE (e-mail: jadsonlee.sa@univasf.edu.br)

^{***} Companhia Hidro Elétrica do São Francisco - CHESF, PE, (e-mail: jbionef,alcidesc,alexcpm,ejatoba@chesf.gov.br)

Abstract: Inspection in photovoltaic generation systems is of utmost importance for maintenance and corresponding generation efficiency. The combined use of unmanned aerial vehicles and deep learning computational algorithms can be considered a potentially strong technique for the automatic inspection of non-conformities present in photovoltaic panels. In this work, a methodology was developed for inspecting a ground-based solar power plant by capturing video collected by drones and analyzing and classifying the resulting images using convolutional neural network models. Subimages cropped from the extracted images were processed and classified into one of four classes: intact panel and with mild, medium and severe non-conformities. Accuracies of up to 96.42% in the classification of non-conformities were obtained.

Resumo: A inspeção em sistemas de geração fotovoltaicos é de extrema importância para a manutenção e correspondente eficiência da geração. O uso combinado de veículos aéreos não tripulados e algoritmos computacionais de aprendizagem profunda pode ser considerado uma técnica potencialmente forte para a inspeção automática de inconformidades presentes nos painéis fotovoltaicos. Neste trabalho, foi desenvolvida uma metodologia de inspeção de uma usina solar terrestre, através da captação de vídeos coletados por *drones* e análise e classificação das imagens resultantes por meio de modelos de redes neurais convolucionais. Subimagens recortadas das imagens extraídas foram processadas e classificadas em quatro classes: painel íntegro e painel com inconformidades leves, médias e graves. Foram obtidos resultados de até 96,42% de acurácia na classificação das inconformidades.

Keywords: Photovoltaic generation; Soiling; Artificial intelligence; Deep learning; Image processing.

Palavras-chaves: Geração fotovoltaica; Sujidade; Inteligência artificial; Deep learning; Processamento de imagens.

1. INTRODUÇÃO

A energia fotovoltaica tem se destacado mundialmente como uma fonte alternativa de energia, relativamente limpa e com custo caindo gradativamente ao longo dos anos (Syafiq et al., 2018). Por ser provida de uma fonte de energia quase inesgotável como é o Sol, a energia fotovoltaica tem sido considerada para diversas aplicações, inclusive sendo utilizadas em usinas para geração de energia elétrica. A região Nordeste apresenta como vantagem a ocorrência de intervalos prolongados de irradiação solar

contínua, o que aumenta a produtividade deste tipo de geração (Rodrigues et al., 2020).

O sistema de geração fotovoltaica utiliza células solares que convertem a radiação solar em energia elétrica. A eficiência dos painéis fotovoltaicos (PFV) está diretamente relacionada à incidência da radiação, que sofre grande influência da sujidade, maior responsável pela deterioração severa do desempenho de geração fotovoltaica (Heinrich et al., 2020). O termo sujidade refere-se a elementos que se depositam nas placas e que ocasionam a interrupção da incidência de radiação, como, por exemplo, neve em locais frios, poeira, folhas de plantas, pólen de flores e

^{*} Os autores agradecem à Chesf e à CAPES pelo apoio financeiro.

excrementos de pássaros. Além da sujeira, outro grave problema que acomete os painéis fotovoltaicos são as fraturas nos vidros que cobrem as placas, o que ocasiona perdas de até 20% na geração fotovoltaica (Al-Soeidat et al., 2019). A detecção precoce destas inconformidades é fundamental para minimizar os seus impactos na plantas geradoras.

A aprendizagem profunda (do inglês, *deep learning*) pode ser entendida como uma subárea em ascensão do campo de inteligência computacional, cujos modelos computacionais vêm apresentando um papel de destaque em relação às técnicas convencionais de aprendizado de máquina (Guo et al., 2016). Ela tem proporcionado ganhos significativos de desempenho em diversas linhas de atuação, tais como robótica (Pierson and Gashler, 2017), visão computacional (Ren et al., 2015) e cuidados na saúde (Waring et al., 2020), entre outras. Estes modelos também se tornaram protagonistas no desenvolvimento de aplicações inteligentes para diagnóstico de isoladores em redes de distribuição (Prates et al., 2019). Uma classe particular de algoritmos de aprendizagem profunda são as redes neurais convolucionais (RNC), uma classe especial de redes neurais artificiais concebida para reconhecer padrões em dados bidimensionais utilizando a operação de convolução (Goodfellow et al., 2016). As RNC vêm demonstrando nos últimos anos excelente desempenho em diversos tipos de aplicações, especialmente em tarefas relacionadas à visão computacional (Chen and Lin, 2014).

A caracterização das inconformidades pode ser feita de maneira otimizada com o auxílio de técnicas de visão computacional, uma vez que a sujeira ocasiona mudanças da cor e textura dos painéis. Para isso, câmeras acopladas a um veículo aéreo não tripulado (VANT) podem coletar imagens dos painéis solares e, através de técnicas computacionais inteligentes, pode-se verificar e quantificar automaticamente a inconformidade. Essa quantificação pode ser usada como auxílio à tomada de decisão para o momento ótimo de aplicação do processo de limpeza dos painéis.

O presente trabalho teve como objetivo desenvolver um sistema inteligente de inspeção visual (SIV) voltado à inspeção de inconformidades em painéis fotovoltaicos em usinas terrestres. O *framework* considerado é composto por um *drone* dotado de câmera e um sistema computacional inteligente para detecção das inconformidades. O objetivo final do trabalho é criar um método para classificar subimagens (*patches*) dos painéis e classificá-las em uma de quatro classes de inconformidades, por meio de uma RNC, de forma a permitir futuras implementações em ambiente real. Os resultados apresentados neste trabalho derivam de um projeto de Pesquisa, Desenvolvimento (P&D) financiado pela Companhia Hidro Elétrica Vale do São Francisco (CHESF), denominado “Plataforma Solar de Petrolina - Desenvolvimento, Pesquisa e Inovação em Tecnologias Avançadas”, que faz parte do Programa de P&D da Agência Nacional de Energia Elétrica (ANEEL).

2. METODOLOGIA

Na Figura 1, pode-se observar a representação gráfica resumindo as etapas implementadas no presente trabalho, que serão detalhadas a seguir.

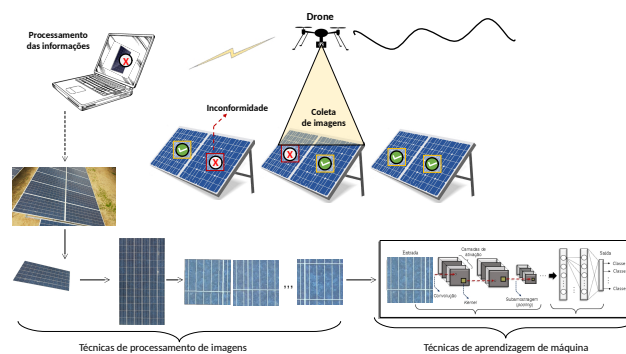


Figura 1. Representação gráfica do *framework* utilizado.

2.1 Coleta das Imagens

Para a composição da base de imagens dos painéis fotovoltaicos, foi empregado um método de coleta que consiste na utilização do *drone* DJI MAVIC AIR 2 FLY MORE, dotado de câmera 4K, controlado manualmente, sobrevoando a Planta Base do Centro de Referência de Energia Solar de Petrolina (CRESP). A planta encontra-se interligada à rede elétrica comercial, apresentando potência nominal mínima de 2,5 MWp e está instalada em uma área próxima à cidade de Petrolina/PE. Foram realizados voos de diferentes durações, com altura de 5m e velocidade máxima de 20 km/h, sendo gravados vídeos com resolução 4K e 60 quadros por segundo (fps, do inglês *frames per second*).

Os vídeos foram manipulados posteriormente, dos quais foram extraídos *frames* com imagens que continham tanto as placas quanto o plano de fundo, salvos no formato PNG. Na Figura 2, está ilustrada uma imagem coletada.



Figura 2. Imagem de painéis fotovoltaicos da planta base no CRESF/CHESF.

2.2 Processamento das Imagens

Nesta etapa, as imagens adquiridas por meio do *drone* foram processadas por meio de técnicas de processamento digital de imagens a fim de torná-las viáveis para aplicação nas RNCs. As etapas do processamento estão detalhadas como segue.

Segmentação manual No campo de visão computacional, a tarefa de segmentação se refere ao processo de dividir uma imagem ou vídeo em diferentes regiões para facilitar a análise de suas informações (Khan et al., 2018). Desta forma, após a obtenção dos *frames* extraídos dos vídeos,

foi aplicada a segmentação manual dos PFVs, utilizando-se a ferramenta gratuita Visual Geometry Group Image Annotator (VIA) (Dutta and Zisserman, 2019). Após finalizadas as segmentações em todos os arquivos desejados, são obtidos arquivo de anotações, de extensão JSON, que contém todas as informações referentes às regiões segmentadas, que correspondem aos painéis fotovoltaicos presentes em cada *frame* extraído dos vídeos.

Em seguida, foi desenvolvido um algoritmo na linguagem Python para leitura automática da imagem anotada e separação da imagem de cada painel para posterior registro (alinhamento). A partir do arquivo de anotação, que gera uma base de dados no formato de dicionário, cada região manualmente segmentada é selecionada individualmente, correspondendo a cada PFV presente na imagem. Isto é feito buscando-se os campos ‘height’, ‘width’ e ‘polygons’ no arquivo JSON, que contém a máscara referente a cada painel (com altura, largura e pixels que formam a máscara, respectivamente). Uma vez extraída esta máscara, com informações binárias, ela é multiplicada pixel a pixel para se obter uma imagem do painel isolado. A Figura 3 ilustra um frame extraído do vídeo e um dos painéis isolados na imagem empregando o algoritmo desenvolvido.



Figura 3. Imagem de painéis fotovoltaicos isolado a partir da segmentação manual.

Pode-se notar que algumas placas não estão com sua área totalmente visíveis no *frame*. Neste caso, foi ainda implementada uma rotina computacional para selecionar apenas painéis que estejam totalmente presentes nas imagens, ou pelo menos que a área visível seja retangular, para permitir a extração de *patches* com dimensões regulares ($224 \times 224 \times 3$ pixels) e facilitar o processo automatizado de extração e classificação. Estas dimensões dos *patches* foram usadas por estarem em conformidade com as dimensões das imagens de entrada dos modelos de RNCs usados. Foram selecionadas apenas os PFVs segmentados que aparecem como retângulos, quadrados ou losangos. Qualquer região com outra forma é descartada do processo.

Para isso, desenvolveu-se uma rotina que se baseou na detecção de borda e canto de Harris (Harris et al., 1988). A detecção de Harris baseia-se no cálculo da derivada discreta calculada pixel a pixel na imagem segmentada, que resulta nos pixels da borda e na procura pelos valores máximos de derivada, onde provavelmente localizam-se os cantos da imagem. O algoritmo foi usado com um elemento estruturante de dimensões 3×3 pixels e com um parâmetro de ajuste do algoritmo, denominado de parâmetro livre

de Harris, no valor 0,05. Como resultado da aplicação, o algoritmo retorna os pixels pertencentes à borda da imagem, inclusive os cantos. Aplicando-se uma limiarização, pode-se obter os pixels dos cantos da imagem, que no presente caso serão quatro coordenadas representando os quatro cantos do quadrilátero correspondente aos painéis fotovoltaicos. Foram considerados apenas os pixels com intensidade acima de 3,5% do máximo retornado pelo algoritmo de Harris.

A segmentação manual descrita foi implementada em 200 imagens de PFVs e delas foram geradas 1532 imagens de *patches* para treinamento e 756 para teste do modelo de RNC usado neste trabalho, que será descrito adiante.

Registro das imagens Como se pode observar a partir da Figura 2, a imagem isolada do painel aparece com distorções geométricas por conta da característica da aquisição das imagens por meio de VANTs. Este posicionamento irregular pode ser prejudicial para o processo de extração de *patches* e posterior classificação. Devido a este comportamento irregular, é necessário aplicar um realinhamento nas imagens. O realinhamento desejado neste projeto implica em deixar a imagem do PFV na posição vertical.

O registro de imagens é uma importante aplicação do processamento de imagens que permite o seu alinhamento em uma determinada cena (Gonzalez and Woods, 2010). Para que seja implementado, o registro de imagens necessita de uma imagem de entrada, que será transformada, e uma imagem de saída, que representa o objetivo do alinhamento e será denominada imagem de referência. Para a implementação do registro de imagens, são usadas transformações geométricas denominadas transformações afins, com base na forma geral:

$$\begin{bmatrix} x & y & 1 \end{bmatrix} = \begin{bmatrix} v & w & 1 \end{bmatrix} \mathbf{T} \quad (1)$$

sendo (v, w) as coordenadas de um pixel na imagem original, (x, y) as coordenadas do pixel correspondente na imagem transformada e \mathbf{T} a matriz de transformação, representada por:

$$\mathbf{T} = \begin{bmatrix} t_{11} & t_{12} & 0 \\ t_{21} & t_{22} & 0 \\ t_{31} & t_{32} & 1 \end{bmatrix} \quad (2)$$

Os valores da matriz de transformação dependem do tipo de transformação que se deseja implementar na imagem original. As principais transformações são a operação de escala, rotação, translação ou cisalhamento, denominadas de transformações afins.

No registro de imagens, estão disponíveis as imagens de entrada e a imagem de referência, mas não se conhece a transformação necessária. Desta forma, é preciso estimar a função de transformação e utilizá-la para registrar as imagens. Embora úteis por preservarem tanto as linhas quanto o paralelismo nas imagens, as transformadas afins não têm aplicação no presente problema, que trata do mapeamento de linhas apenas, sem necessariamente manter o paralelismo entre elas (as bordas dos quadriláteros). Para isso, utiliza-se a transformação projetiva ou homografia, sendo um caso geral de transformação afim, que preserva as linhas de uma imagem, sem necessariamente manter o paralelismo. A estimativa da função de transformação é feita baseada em pontos de controle estabelecidos tanto na imagem original quanto na imagem de referência. No

caso presente, os pontos de controle da imagem original são os quatro cantos da imagem do PFV segmentado. Os pontos de controle da imagem de referência seriam os cantos superiores e inferiores de uma imagem vertical.

A homografia se baseia em estimar uma matriz 3×3 por meio da transformada linear direta (Radke, 2009), representada pela equação:

$$[x \ y \ 1] = [v \ w \ 1] \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & 1 \end{bmatrix} \quad (3)$$

Desta maneira, a partir de quatro pontos de referência, tem-se um sistema linear de equações que é resolvido por meio da decomposição da matriz em valores singulares (SVD, do inglês). Como se pode observar das Equações (1) e (3), a transformação projetiva em um caso geral das transformações afins. Posteriormente à transformação estimada, deve-se ainda implementar uma interpolação, pois pode haver posições (coordenadas x e y) fracionárias. A interpolação consiste na atribuição de intensidades aos pontos que não se encontram na imagem registrada. As mais comumente usadas são: interpolação por vizinho mais próximo, a bilinear, a bicúbica e a por polinômios de Lagrange. Para este trabalho, foi usada a interpolação bilinear. A Figura 4 apresenta como exemplo o resultado do registro de um dos painéis da imagem considerada na Figura 2.



Figura 4. Imagem de painel fotovoltaico após os processos de segmentação e registro.

Recorte dos patches Cada imagem registrada seguindo o procedimento da seção anterior foi aplicada a uma rotina computacional de recorte de *patches* para posterior classificação. Estas imagens recortadas possuem o propósito de separar/evidenciar regiões das placas solares com informações úteis para as etapas de treinamento e teste dos modelos computacionais que foram implementados nesta etapa do projeto. As Figuras 5 (a) e (b) ilustram exemplos de *patches* de imagens de regiões íntegras e com inconformidades dos painéis solares, respectivamente. Os patches extraídos foram separados em quatro diferentes classes de inconformidades, a saber:

- Íntegro (Classe 0) – imagens de partes íntegras dos painéis monitorados;
- Leve (Classe 1) – imagens com poeira, alteração de coloração ou pequenas manchas;
- Média (Classe 2) – imagens com fezes de animais, folhas ou outros objetos ou terra em grande quantidade;
- Grave (Classe 3) – imagens com fraturas no painel.

Estas classes foram definidas como saídas de um classificador baseado em RNCs e as imagens de *patches* obtidas foram divididas em dois grupos: 2/3 de cada classe foram usadas para treinamento e validação do modelo e 1/3 do total de cada classe foi usado para testar a generalização do modelo para dados não conhecidos. Os detalhes serão explicitados na seção seguinte.




Figura 5. *Patches* de imagens de regiões íntegras (a) e com inconformidades (b) dos painéis fotovoltaicos.

2.3 Classificação automatizada de inconformidades

O SIV proposto deve possuir a funcionalidade de identificar as áreas fotossensíveis de matrizes de PFVs, através de técnicas de segmentação instanciada de imagens e vídeos, que não é o escopo deste trabalho, como também deve ser capaz de detectar/classificar os diferentes tipos de inconformidades investigadas. Para tal, realizou-se o desenvolvimento de rotinas computacionais destinadas à classificação das inconformidades detalhadas anteriormente. Deste modo, os modelos computacionais devem ser capazes de diferenciar a condição íntegra da placa solar em relação às inconformidades definidas como leve, média e grave.

Para estes experimentos, objetivou-se desenvolver uma metodologia inteligente que apresentasse as seguintes características fundamentais: possuir alto nível de imunidade a fontes de ruído de planos de fundo – condição conhecida como *background invariance* (Cruz et al., 2021); gerar base de dados mais diversificada e semelhante às estatísticas do domínio real do objeto de estudo a partir de uma base simplificada; possuir o menor custo computacional possível para o processamento da informação; e apresentar bons desempenhos de classificação para diferentes tipos de inconformidades que podem estar presentes em regiões fotossensíveis de PFVs.

A partir destes objetivos, foram selecionados dois tipos de redes convolutivas para a investigação dos desempenhos de classificação multi-classes. A primeira delas foi uma rede de aprendizagem profunda que apresenta uma arquitetura clássica, possuindo apenas seis camadas convolutivas combinadas a três camadas de agrupamento e duas camadas totalmente conectadas. Esta RNC foi intitulada como rede *baunilha*, devido à simplicidade da sua configuração. Ela apresenta uma topologia bem estabelecida na literatura especializada (Goodfellow et al., 2016) e demanda um

baixo custo computacional para processamento da informação, se comparada com outros modelos conhecidos de aprendizagem profunda (Prates et al., 2019). A Figura 6 ilustra, de forma simplificada, a planta arquitetural desta RNC.




Figura 6. Arquitetura simplificada da rede convolutiva do tipo *baunilha*.

Para o segundo caso, foi utilizada uma rede convolutiva desenvolvida por François Chollet, no ano de 2017. Esta RNC é intitulada de Xception (do inglês, *Extreme Inception*) e, de acordo com o próprio criador, apresenta uma arquitetura de rede neural convolutiva baseada inteiramente em camadas de convolução separáveis em profundidade. Este modelo foi selecionado por apresentar desempenhos satisfatórios em demandas de classificação de imagens (Chollet, 2017) e ele também segue uma hipótese que foi explorada pela equipe de pesquisa do P&D: o mapeamento de correlações de canais cruzados e correlações espaciais nos mapas de características das redes neurais convolucionais pode ser totalmente desacoplado, o que pode resultar tanto em bons desempenhos de classificação como em um custo computacional inferior a outros modelos de aprendizagem profunda que apresentam resultados similares. A planta arquitetural desta RNC, contendo os principais fluxos de processamento da informação, pode ser visualizada na Figura 7.

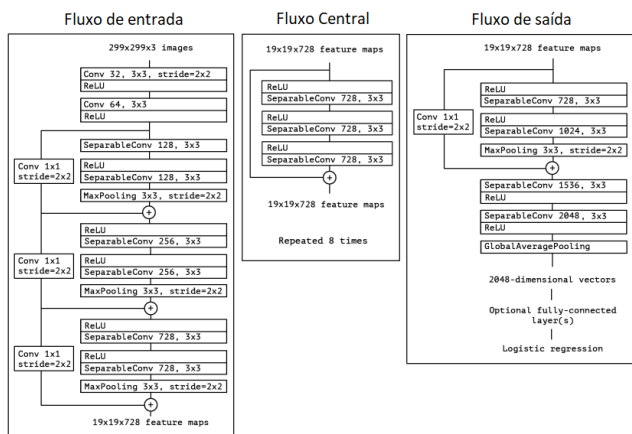


Figura 7. Arquitetura da rede convolutiva Xception. Adaptado de (Chollet, 2017).

3. RESULTADOS

Nesta seção, serão apresentados os resultados obtidos com ambas as redes definidas anteriormente. Em ambos os casos, do total de 756 *patches* gerados foram usados 2/3 para treinamento e 1/3 do total das imagens para teste do modelo treinado. Para o modelo *baunilha*, todas as camadas da rede foram treinadas com a base de treinamento.

No caso da Xception, com o intuito de acelerar o processo de aprendizagem e otimizar os desempenhos de classificação, foi implementada a técnica de transferência de conhecimento para realizar o treinamento do modelo. O *dataset* utilizado para a etapa de pré-treinamento foi o ImageNet (Deng et al., 2009).

3.1 Avaliação do modelo

A principal ferramenta para analisar o desempenho dos classificadores são medidas extraídas da chamada matriz de confusão (Witten and Frank, 2002). A diagonal principal da matriz de confusão é responsável pelas previsões corretas do classificador, onde TP e TN indicam, respectivamente, os verdadeiros positivos e os verdadeiros negativos. A diagonal secundária mostra as previsões incorretas do classificador, onde FP e FN representam, respectivamente, os falsos positivos e os falsos negativos.

A partir da matriz de confusão, outras métricas importantes podem ser calculadas. A acurácia (*Acc*) é uma medida que representa a relação entre as previsões corretas e o número total de previsões. Como leva em conta tanto a classe positiva quanto a negativa, ela é considerada a principal medida para avaliar os classificadores e pode ser obtida pela seguinte equação:

$$Acc = \frac{TP + TN}{TP + FP + FN + TP} \quad (4)$$

3.2 Apresentação dos resultados

A rede baunilha apresentou uma *Acc* de classificação de 92%, enquanto o modelo Xception obteve a acurácia de 96,42%. A matriz de confusão e ela normalizada provenientes do modelo Xception são apresentadas na Figura 8. Nela, é possível identificar que o modelo enfrenta maior dificuldade de diferenciar a Classe 1 (superfície com inconformidade do tipo leve) da Classe 0 (superfície íntegra), apresentando o menor percentual de *Acc* para a Classe 1 – 87%. Diante deste resultado, pretende-se investigar formas de tornar este modelo computacional mais sensível às diferenças entre a inconformidade leve e a superfície íntegra.




Figura 8. Matriz de confusão sem e com normalização da rede convolutiva Xception para quatro classes distintas: (0) superfície íntegra; (1) inconformidade leve; (2) inconformidade média; (3) inconformidade grave.

Com o propósito de fornecer evidências visuais de comportamentos internos apresentados pelos modelos computacionais trabalhados, foram implementadas rotinas para

geração de mapas de calor ou, do inglês, *heat-maps* (Seifert et al., 2017). Estes *heat-maps* possibilitam investigar características internas dos modelos de aprendizagem profunda através de suas respectivas sensibilidades para as imagens de entrada. As matrizes relativas aos mapas de calor, definidas como $h_{x,y,z}$, são usualmente produzidas a partir do gradiente da soma das saídas de cada k -ésima classe predita, \hat{P}_k , em função de cada pixel de entrada e cores dos canais RGB, definidos por $X_{x,y,z}$, através da equação:

$$g_{x,y,z} = \frac{\partial \sum_k \hat{P}_k}{\partial X_{x,y,z}} \quad (5)$$

Dependendo da técnica utilizada, a matriz gerada pode ser colorida ou monocromática e advém da escolha da cor absoluta máxima para cada pixel, com posterior etapa de normalização. Na etapa final, $h_{x,y,z}$ (que é uma função de $g_{x,y,z}$) é então mesclada à imagem original de entrada. Neste trabalho, foi implementada uma rotina para geração de *heat-maps*, intitulada de Grad-CAM - do inglês, *Gradient-weighted Class Activation Mapping* (Selvaraju et al., 2017). A referida técnica tem o potencial de fornecer informações visuais que realçam regiões importantes nas imagens das placas solares após o processo de predição das classes avaliadas.

A Figura 9 ilustra o *heat-map* (imagem ao centro) produzido para um *patch* (imagem à esquerda) de uma região fotossensível de PFV com a presença de um defeito do tipo médio (Classe 2). À direita, é possível visualizar a imagem mesclada, constituída pela combinação do *patch* original com o mapa de calor. Neste caso avaliado, correspondente a um erro de classificação da RNC do tipo *baunilha*, pode-se observar que a sujidade não sensibilizou o modelo computacional adequadamente, haja vista que a região inconforme da imagem produziu uma zona escura no mapa de calor. Esta condição indica pouca influência da sujidade no processo de classificação do modelo computacional. No caso deste *patch* avaliado, as regiões mais claras, que produzem maior influência no processo de classificação, ficaram restritas às linhas brancas divisórias do PFV. Deste modo, foi possível identificar que o classificador do modelo *baunilha* não atendeu às demandas de classificação desejadas.




Figura 9. Exemplo de mapa de calor produzido pelo modelo *baunilha* para uma imagem de entrada.

Considerando exemplos de mapas de calor produzidos pelo classificador Xception, apresentados na Figura 10, pode-se visualizar que as regiões das imagens de teste mais sensibilizadas pelo classificador contemplam as sujidades presentes no painel solar. Deste modo, a partir da avaliação dos desempenhos de classificação (acurácia geral supracitada) e respectivos mapas de calor, pode-se inferir que este

modelo computacional foi adequadamente implementado para identificação de sujidades de nível médio nos PFVs.




Figura 10. Exemplos de mapas de calor produzidos pelo classificador Xception para *patches* de PFVs contendo sujidades de nível médio.

4. CONCLUSÃO

Neste artigo, foi criada uma metodologia para classificação de inconformidades em painéis fotovoltaicos, a partir das imagens extraídas de vídeos com uso de *drones* e câmeras de alta resolução. Foram desenvolvidos algoritmos computacionais automatizados para alinhamento das imagens dos painéis e recorte de subimagens (*patches*) de cada imagem alinhada. Estes *patches* foram rotulados em quatro classes de inconformidades (leve, médio, grave e íntegro) e usados como entradas de algoritmos inteligentes para classificação dos *patches* em uma das classes. Foram usados dois modelos de RNCs, uma denominada *baunilha*, cujas camadas foram completamente treinadas, e outra adaptada da rede Xception, para a qual usou-se a transferência de aprendizado em modelos previamente treinados para outros fins. Foram obtido resultados na classificação das quatro inconformidades com acurácia de 92% para a rede *baunilha* e de 96,42% para a rede Xception. Novas investigações ainda serão conduzidas para avaliação da resposta destes sistemas de classificação para outros tipos de inconformidades, assim como serão considerados algoritmos de automatização do processo de segmentação dos PFVs.

AGRADECIMENTOS

Os autores agradecem à CHESF e à ANEEL pelo apoio financeiro.

REFERÊNCIAS

- Al-Soeidat, M., Cheng, T., Lu, D.D.C., and Agelidis, V.G. (2019). Experimental study of static and dynamic behaviours of cracked pv panels. *IET Renewable Power Generation*, 13(16), 3002–3008.
- Chen, X.W. and Lin, X. (2014). Big data deep learning: challenges and perspectives. *IEEE access*, 2, 514–525.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251–1258.
- Cruz, R., Prates, R.M., Simas Filho, E.F., Costa, J.F.P., and Cardoso, J.S. (2021). Background invariance by adversarial learning. In *2020 25th International Conference on Pattern Recognition (ICPR)*, 5883–5888. IEEE.
- Deng, J., Dong, W., Socher, R., Li, L.J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, 248–255. Ieee.

- Dutta, A. and Zisserman, A. (2019). The via annotation software for images, audio and video. In *Proceedings of the 27th ACM international conference on multimedia*, 2276–2279.
- Gonzalez, R.C. and Woods, R.C. (2010). *Processamento digital de imagens*. Pearson, 3a. edition.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., and Lew, M.S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48.
- Harris, C., Stephens, M., et al. (1988). A combined corner and edge detector. In *Alvey vision conference*, volume 15, 10–5244. Citeseer.
- Heinrich, M., Meunier, S., Same, A., Queval, L., Darga, A., Oukhellou, L., and Multon, B. (2020). Detection of cleaning interventions on photovoltaic modules with machine learning. *Applied Energy*, 263, 114642.
- Khan, S., Rahmani, H., Shah, S.A.A., and Bennamoun, M. (2018). A guide to convolutional neural networks for computer vision. *Synthesis Lectures on Computer Vision*, 8(1), 1–207.
- Pierson, H.A. and Gashler, M.S. (2017). Deep learning in robotics: a review of recent research. *Advanced Robotics*, 31(16), 821–835.
- Prates, R.M., Cruz, R., Marotta, A.P., Ramos, R.P., Simas Filho, E.F., and Cardoso, J.S. (2019). Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *Computers & Electrical Engineering*, 78, 343–355.
- Radke, R.J. (2009). Multiview geometry for camera networks. *Multi-camera networks: principles and applications*.
- Ren, S., He, K., Girshick, R., and Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- Rodrigues, P.S.F., Jatobá, E.B., da Nobrega, D.B.G., and de Melo Filho, J.B. (2020). Plataforma fotovoltaica flutuante de sobradinho (ba)-desafios e estratégias de implantação. In *VII Congresso Brasileiro de Energia Solar-CBENS 2018*.
- Seifert, C., Aamir, A., Balagopalan, A., Jain, D., Sharma, A., Grottel, S., and Gumhold, S. (2017). Visualizations of deep neural networks in computer vision: A survey. In *Transparent data mining for big and small data*, 123–144. Springer.
- Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE international conference on computer vision*, 618–626.
- Syafiq, A., Pandey, A., Adzman, N., and Abd Rahim, N. (2018). Advances in approaches and methods for self-cleaning of solar photovoltaic panels. *Solar Energy*, 162, 597–619.
- Waring, J., Lindvall, C., and Umeton, R. (2020). Automated machine learning: Review of the state-of-the-art and opportunities for healthcare. *Artificial Intelligence in Medicine*, 104, 101822.
- Witten, I.H. and Frank, E. (2002). Data mining: practical machine learning tools and techniques with Java implementations. *Acm Sigmod Record*, 31(1), 76–77.