

# DETECÇÃO AUTOMÁTICA DE FALHAS DE SISTEMAS FOTVOLTAICOS POR REDES NEURAIIS CONVOLUCIONAIS UTILIZANDO A TERMOGRAFIA AÉREA INFRAVERMELHA

**Aline Kirsten Vidal de Oliveira** (UFSC) - alinekvo@gmail.com

**Mohammedreza Aghaei** (Instituição - a informar) - aghaei1984@gmail.com

**Ricardo Rütther** (UFSC) - rruther@gmail.com

## **Resumo:**

*A Termografia Infravermelho Aérea (aIRT) é um método não destrutivo e econômico para detectar falhas em usinas fotovoltaicas (FV) de larga escala. No entanto, a avaliação visual das imagens capturadas pela aIRT e a análise de um grande número de quadros de imagens consomem muito tempo. Este artigo propõe um método para detectar e classificar falhas em módulos FV, através de imagens aIRT, combinando os algoritmos de Processamento de Imagens (DIP) e Redes Neurais Convolucionais (CNNs). Com os resultados obtidos até o momento, as imagens adquiridas foram processadas com sucesso com técnicas de DIP para detectar as falhas dos módulos FV em usinas, que são usadas como amostras para o treinamento da CNN. O algoritmo de rede neural desenvolvido pode detectar falhas nas imagens aIRT e classificá-las em três categorias: subséries desconectados, pontos quentes e séries desconectados. Os resultados demonstraram que o método é eficaz na detecção e classificação de falhas e é uma etapa importante para a automação completa da inspeção de aIRT.*

**Palavras-chave:** *Desempenho de sistemas, monitoramento, inteligência artificial.*

**Área temática:** *Conversão Fotovoltaica*

**Subárea temática:** *Controle e monitoramento de sistemas fotovoltaicos*

# DETECÇÃO AUTOMÁTICA DE FALHAS DE SISTEMAS FOTOVOLTAICOS POR REDES NEURAIAS CONVOLUCIONAIS UTILIZANDO A TERMOGRAFIA AÉREA INFRAVERMELHA

**Aline Kirsten Vidal de Oliveira** – [alinekvo@gmail.com](mailto:alinekvo@gmail.com)

Universidade Federal de Santa Catarina, Laboratório Fotovoltaica-UFSC

**Mohammedreza Aghaei** – [aghaei1984@gmail.com](mailto:aghaei1984@gmail.com)

University of Freiburg, Freiburg im Breisgau

**Ricardo Rütther** – [rruther@gmail.com](mailto:rruther@gmail.com)

Universidade Federal de Santa Catarina, Laboratório Fotovoltaica-UFSC

**Resumo.** A Termografia Infravermelho Aérea (aIRT) é um método não destrutivo e econômico para detectar falhas em usinas fotovoltaicas (FV) de larga escala. No entanto, a avaliação visual das imagens capturadas pela aIRT e a análise de um grande número de quadros de imagens consomem muito tempo. Este artigo propõe um método para detectar e classificar falhas em módulos FV, através de imagens aIRT, combinando os algoritmos de Processamento de Imagens (DIP) e Redes Neurais Convolucionais (CNNs). Com os resultados obtidos até o momento, as imagens adquiridas foram processadas com sucesso com técnicas de DIP para detectar as falhas dos módulos FV em usinas, que são usadas como amostras para o treinamento da CNN. O algoritmo de rede neural desenvolvido pode detectar falhas nas imagens aIRT e classificá-las em três categorias: subséries desconectados, pontos quentes e séries desconectados. Os resultados demonstraram que o método é eficaz na detecção e classificação de falhas e é uma etapa importante para a automação completa da inspeção de aIRT.

**Palavras-chave:** Desempenho de sistemas, monitoramento, inteligência artificial.

## 1. INTRODUÇÃO

Atualmente, a energia fotovoltaica (FV) é o segmento de energia renovável que mais cresce no mundo. O PV tornou-se uma fonte de energia competitiva e tem um grande potencial de expansão, especialmente nos chamados países do cinturão do sol (Sunbelt countries). O Brasil é um desses exemplos, ultrapassando a marca de 2GW de capacidade instalada em sistemas FV de grande porte em 2019 (ANEEL, 2019).

À medida que a competitividade do FV aumenta no mercado de energia, a confiabilidade da tecnologia é uma grande preocupação no setor de energia solar. Portanto, métodos confiáveis e econômicos de operação e manutenção (O&M) para usinas FV são de extrema importância para garantir a segurança, disponibilidade e produtividade dos sistemas.

Nos últimos anos, vários métodos de inspeção e diagnóstico de falhas foram desenvolvidos. Os métodos mais comuns incluem inspeção visual, medição de desempenho (por exemplo, traçado da curva I-V), eletroluminescência (EL) e termografia infravermelha (IRT). Entre esses métodos, a IRT é um dos métodos mais populares e confiáveis de diagnóstico de falhas, pois é um método não destrutivo, requer instrumentação mínima e pode ser realizado sem interromper a operação de usinas FVs. Além disso, ao contrário das medições elétricas, fornece informações sobre a localização física exata de um defeito de maneira rápida e fácil (Buerhop et al., 2012).

Para aumentar a precisão e acelerar o procedimento de detecção de falhas para usinas FVs em escala de megawatts ou sistemas FV com acesso limitado, como em telhados ou fachadas, a IRT pode ser combinada com veículos aéreos não tripulados (VAnTs) (Aghaei et al., 2014; Quater et al., 2014; Tsanakas and Botsaris, 2012; Vidal de Oliveira et al., 2019). A inspeção aérea através de VAnTs tem a vantagem de ser um método de inspeção rápido, não-destrutivo e sem contato necessário, que pode ser aplicado em condições operacionais em tempo real. O uso dessa técnica tornou-se mais difundido nos últimos anos, principalmente em usinas de silício multicristalino (m-Si).

No entanto, a avaliação visual das imagens capturadas pela aIRT e a análise de um grande número de quadros de imagem são lentos. Uma solução para o problema é automatizar o procedimento de detecção de falhas combinando o aIRT com técnicas de DIP, conforme proposto por muitos autores (Aghaei et al., 2015; John A. Tsanakas, Godefroy Vannier, Alexandre Plissonnier, Duy Long Ha, 2016; Kim et al., 2017; Rogotis et al., 2014).

Uma maneira melhor de abordar o problema é aplicar redes neurais artificiais (RNAs) para categorizar os diferentes tipos de falhas nos módulos FV. Estes pretendem imitar a maneira como o cérebro humano executa uma tarefa de interesse; portanto, eles são normalmente mais assertivos em tarefas complexas do que as técnicas tradicionais de computação (Mayo and Leung, 2018). Entre as muitas arquiteturas diferentes de RNAs, as Redes Neurais Convolucionais (CNNs) demonstram clara superioridade em tarefas de reconhecimento visual, como classificação de

imagens e detecção de objetos. Seu treinamento é de baixa complexidade e gera resultados coerentes, mesmo quando as imagens são capturadas em diferentes condições (Geng et al., 2018).

Este método já foi explorado para detecção de falhas em Pierdicca et al (2018), apresentando resultados de alta qualidade. No entanto, o conjunto de dados criado foi baseado em anotadores humanos, que segmentaram manualmente 3336 imagens térmicas. Portanto, esse procedimento, apesar de eficaz, consome muito tempo para replicar a técnica usando câmeras diferentes e diferentes alturas de voo. Uma solução para o problema é combinar técnicas de DIP para criar o conjunto de dados necessário para treinar a CNN.

Este artigo propõe um novo método para detectar e classificar falhas em módulos FV, por meio de imagens de aIRT, combinando algoritmos DIP e CNNs.

## 2. MÉTODOS

O método proposto consiste em quatro etapas principais: a aquisição de imagens aIRT, as técnicas de aplicação de DIP para análise de imagens, a criação de um conjunto de dados e a classificação ou detecção de falhas pela CNN. As etapas são descritas nas seguintes subseções.

### 2.1 Aquisição de Imagens

Para aquisição de imagens, um sistema de medição de aIRT baseado em VAnT foi desenvolvido usando um modelo DJI Phantom 3 Advanced, conforme descrito em (de Oliveira et al., 2018). O VAnT foi manipulado e equipado com uma câmera IRT leve (Thermoteknix MicroCAM 2) e um sistema de transmissão de vídeo. A câmera IRT possui uma faixa de resposta espectral entre 7 e 17  $\mu\text{m}$  e sua resolução é de 640 pixels. Os vídeos capturados têm uma taxa de quadros de 60 FPS. O conjunto de dados consiste em quadros dos vídeos gravados em escala de cinza e as diferenças de intensidade representam a distribuição de temperatura nos módulos.

As imagens foram tiradas durante a inspeção de uma usina FV de 37 MWp, cobrindo uma área de 97 hectares no nordeste do Brasil. A planta FV consiste em mais de cem rastreadores de eixo único N-S. Cada rastreador controla o movimento de mais de cem módulos FV de 72 células de m-Si. A inspeção foi realizada durante o comissionamento da usina, resultando na detecção de 86 módulos com subséries desconectadas, 8 séries desconectados e dois pontos quentes.

O procedimento de inspeção e as condições de voo foram determinados pela IEC TS 62446-3 (International Electrotechnical Commission and International Electrotechnical Commission (IEC), 2017). A altitude de voo foi definida em 20 m para detectar defeitos e falhas nos módulos FV e para que o campo de visão possa cobrir pelo menos três fileiras de seguidores ao mesmo tempo. A rota do voo foi definida através das coordenadas GPS, para que o voo fosse estável a uma velocidade constante. A duração da inspeção foi de aproximadamente 7 dias.

### 2.2 Algoritmo DIP para análise de imagens

As imagens adquiridas foram capturadas em escala de cinza, o que permite uma visualização melhor das falhas em relação a imagens coloridas. Em escala de cinza, cada pixel tem um intervalo de intervalo entre 0 e 255 (0 para áreas pretas e 255 para áreas brancas). Assim, a luminância de um pixel é geralmente descrita por um único byte, o que corresponde a um de 256 níveis. O processo de DIP inicia com o pré-processamento das imagens. A primeira etapa do pré-processamento é a filtragem para eliminar os efeitos de ruído. Um filtro gaussiano é escolhido para diminuir o ruído, destacando os limites dos módulos FV e facilitando a etapa de segmentação (Aghaei et al., 2015). Em seguida, o contraste é ajustado para destacar as bordas dos módulos FV para as próximas etapas e um filtro de redução de olho de peixe adicional é aplicado para minimizar a distorção da câmera.

Para a detecção das áreas da imagem que correspondem às falhas, a chamada etapa de segmentação, as bordas da imagem devem ser destacadas. Nesse caso, um filtro comumente utilizado é o operador Laplaciano, que calcula o gradiente da imagem. Ele destaca descontinuidades de nível de cinza em uma imagem e enfatiza alterações de nível de cinza que variam lentamente. O Laplaciano é muito útil no processo de detecção de bordas, tornando a borda dos módulos FV mais visíveis. Como o operador do Laplaciano é muito sensível ao ruído, a etapa de filtragem supracitada é de extrema importância (Filho and Neto, 1999).

O passo seguinte é transformar a imagem em uma imagem binária, usando um filtro de limiar, o chamado *threshold*. O limiar seleciona as áreas da imagem mais claras que um determinado nível, e foi escolhido após inúmeras tentativas. Após esse processo, o resultado é uma máscara em preto e branco, que possui os pixels mais claros da imagem original como 1 e os mais escuros como 0. A imagem binária também passa por um processo de preenchimento de furos, quando possíveis furos são excluídos, tornando a imagem mais nítida. Operadores morfológicos como dilatação e abertura são aplicados para filtrar os segmentos e obter apenas os segmentos de interesse. A máscara final terá os pixels correspondentes às falhas na imagem original como 1 e o restante dos pixels como 0.

### 2.3 Criação do conjunto de dados

Com base em Vath (2016), as falhas detectadas são classificadas em três categorias: séries desconectadas, pontos quentes e subséries desconectados. Para aumentar o número de imagens para o conjunto de dados, técnicas de aumento

são implementadas. Esse processo aumenta artificialmente o número de segmentos, com o objetivo de melhorar o procedimento geral de aprendizagem e o desempenho, treinando o modelo com dados variados (Kamilaris and Prenafeta-Boldú, 2018). As transformações preservam os rótulos e incluem rotações, cortes, redimensionamentos, transposição e espelhamento dos segmentos.

O conjunto de dados final consiste em imagens de infravermelho com sua segmentação desejada correspondente, obtida com o algoritmo DIP. Os dados estão preparados para dois testes diferentes: o primeiro usa uma quantidade equilibrada de amostras para cada categoria e é limitado pelo número de quadros disponíveis da falha menos comum no conjunto de dados (pontos quentes), e o segundo usa categorias desequilibradas, por isso tem uma chance maior de desempenhar melhor na detecção da categoria de falha com mais amostras (subséries desconectadas). Nos dois conjuntos de dados, 70% das amostras são usadas para treinamento, 10% para validação e 20% para testes, como é comum na literatura. As imagens usadas para testes foram obtidas em locais diferentes do conjunto de imagens de treinamento, de maneira a não interferir na eficácia da rede. A mesma proporção é aplicada para cada classe.

## 2.4 Classificação automática

Para a classificação automática, o ajuste fino de um modelo pré-treinado VGG-16 no domínio de Segmentação em Primeiro Plano é empregado usando Keras e Tensor Flow (Arge and Mage, 2015). As entradas do algoritmo são as imagens aIRT e a saída, imagens binárias com a segmentação das falhas. Para evitar sobreajuste, ou *overfitting*, é aplicada um *dropout* com uma taxa de 50% (Krizhevsky et al., 2012). Para a avaliação do desempenho do algoritmo, algumas métricas serão utilizadas como precisão, eficiência e sensibilidade dos resultados obtidos.

## 3. RESULTADOS

Após o procedimento de aquisição das imagens na usina FV no Nordeste do Brasil, os quadros dos vídeos coletados foram analisados e armazenados para o processo de DIP. Foi possível obter resultados satisfatórios com técnicas convencionais de visão computacional para segmentar as falhas dos módulos. Foi necessário desenvolver vários algoritmos de DIP para diferentes falhas com base em suas formas específicas.

A Fig. 1 ilustra algumas etapas do DIP após o pré-processamento das imagens aIRT. A Fig. 1 (a) mostra a imagem inicial pré-processada que contém um ponto quente e uma subsérie desconectada. A Fig. 1 (b) mostra a imagem após um filtro de limiar. As áreas azuis são mais claras que o limite escolhido e são selecionadas para as próximas etapas. Como os pixels mais claros da imagem representam os objetos com temperatura mais alta, o filtro selecionou as falhas nos módulos e o solo. A Fig. 1 (c) mostra como fica o segmento (em amarelo) após um processo de fechamento, o que elimina os furos em um segmento que é menor que o núcleo escolhido. A Fig. 1 (d) apresenta o segmento resultante após a exclusão de todas as áreas que tocam a borda das imagens. Isso elimina o terreno das imagens, portanto o segmento selecionado restante contém apenas as falhas dos módulos. A Fig. 1 (e) mostra o resultado do algoritmo DIP, após uma abertura do segmento para eliminar possíveis ruídos. As imagens demonstram que é possível segmentar as falhas nas imagens usando técnicas DIP. Após o processamento, as imagens foram classificadas e os segmentos não apropriados foram excluídos. Essa filtragem é importante para fornecer um conjunto de dados de aprendizado adequado para a CNN. Posteriormente, o conjunto de dados foi preparado para a detecção e classificação de falhas.

O algoritmo de segmentação automática baseado no VGG-16 foi bem-sucedido na detecção de falhas determinadas, como mostrado na Fig. 2. As imagens mostram dois exemplos de imagens usadas para validar a precisão do método. A Fig. 2 (a) e a Fig. 2 (c) mostram imagens de entrada de aIRT que a CNN recebe para análise. A Fig. 2 (b) e a Fig. 2 (d) mostram a segmentação gerada como saída. Ambas as imagens contêm módulos FV com uma subsérie desconectada, que foram efetivamente detectados pelo algoritmo CNN.

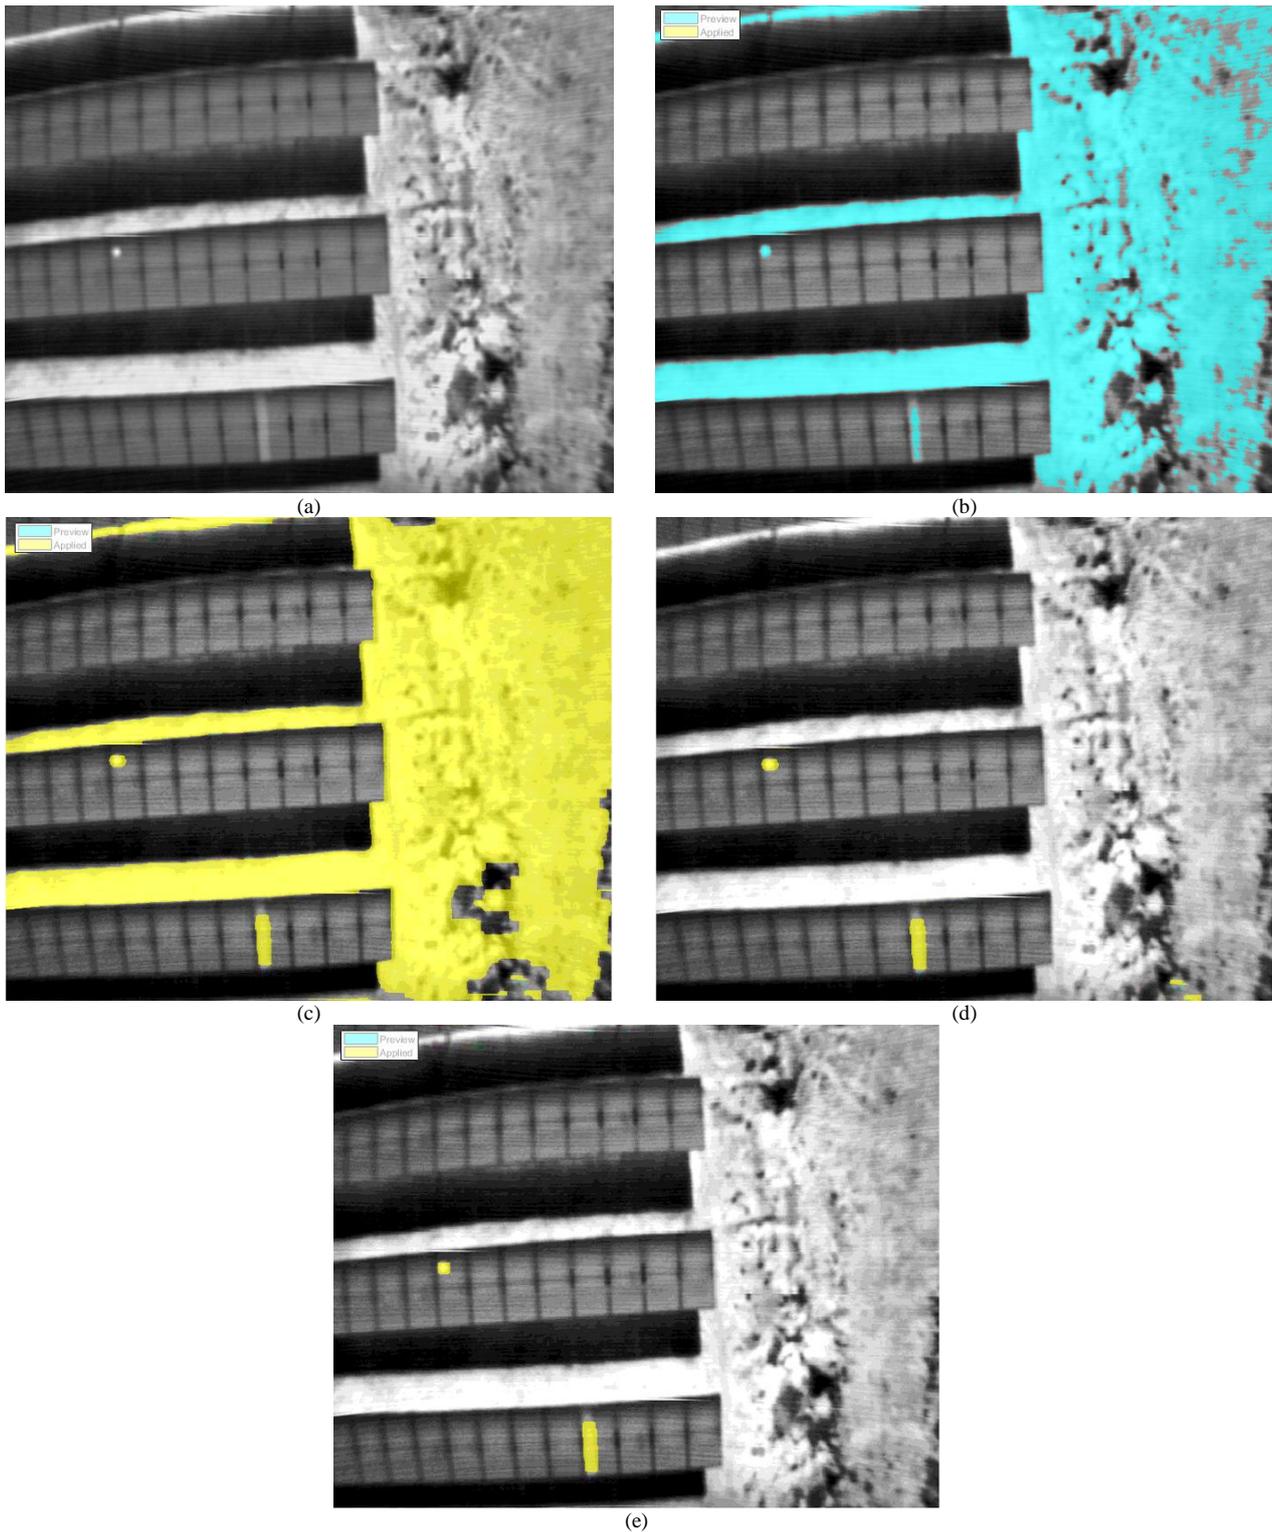


Figura 1 - Etapas da segmentação de falhas em uma imagem aIRT. (a) Imagem pré-processada (b) Imagem após a aplicação do filtro de limiar. (c) Imagem após o fechamento do segmento (d) Imagem após a eliminação das bordas (e) Imagem final após a abertura do segmento.

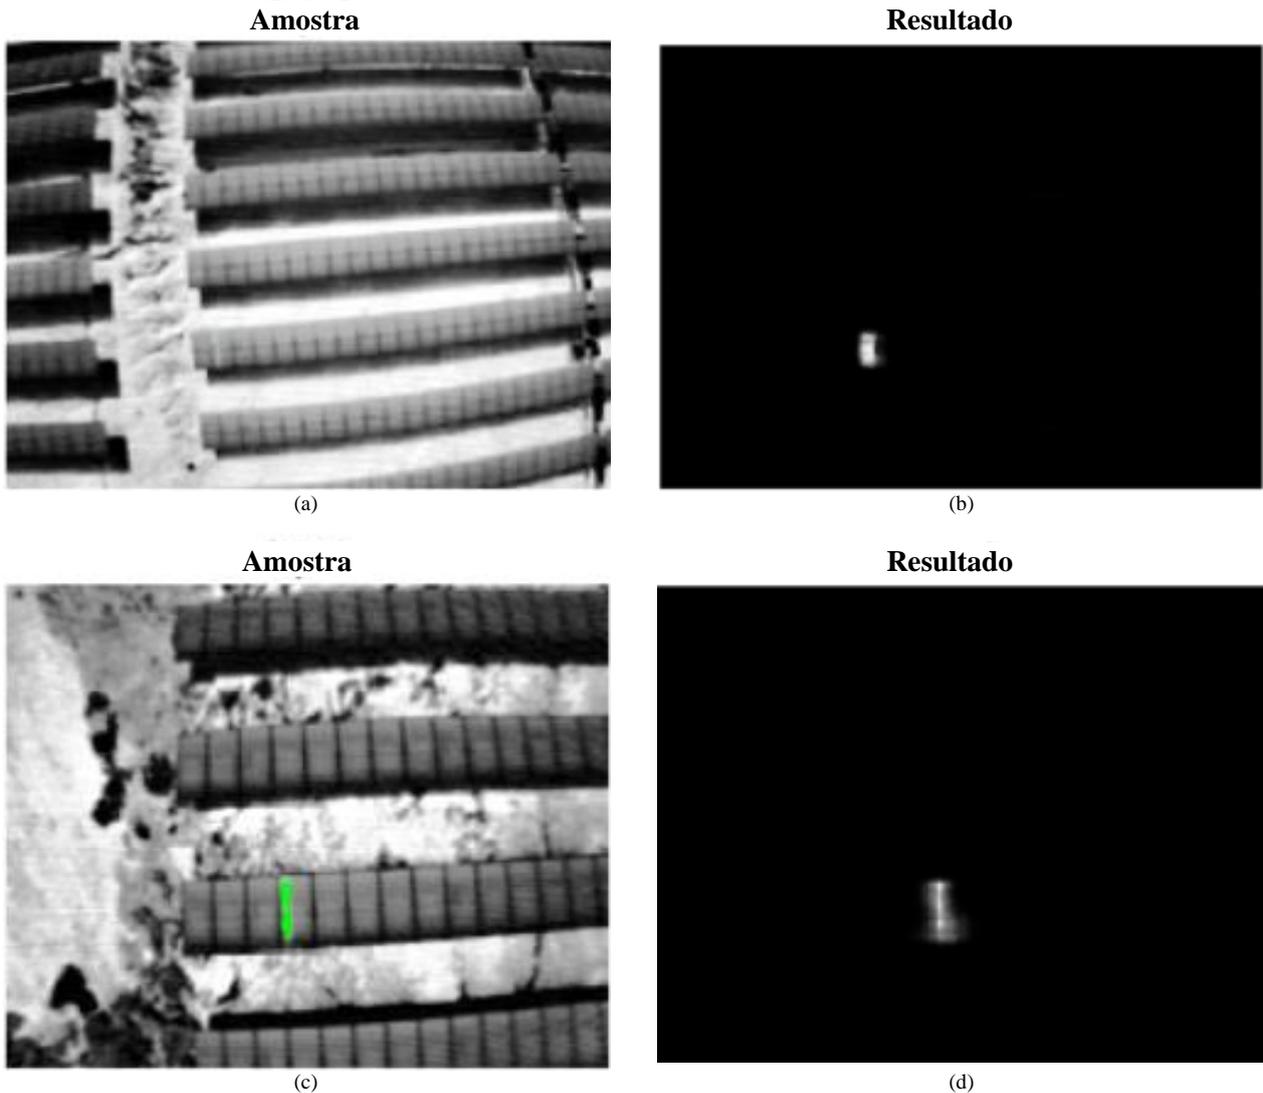


Figura 2 - Dois exemplos de amostras usadas como entrada do algoritmo de segmentação para testes e os resultados obtidos na detecção de módulos FV com subséries desconectadas. (a) imagem de aIRT do primeiro exemplo. (b) Resultado do algoritmo para o primeiro exemplo. (c) imagem de aIRT do segundo exemplo. (d) Resultado para o segundo exemplo.

Resultados satisfatórios também foram obtidos na detecção de séries desconectadas. A Fig. 3 mostra dois exemplos dessas falhas que foram detectadas com sucesso pelo método. As Fig. 3 (a) e Fig. 3 (c) apresentam imagens de aIRT com séries desconectadas e as Fig. 3 (b) e Fig. 3 (d) apresentam o resultado obtido com o algoritmo. Para o primeiro caso, uma série aberta e um problema de subsérie foram detectados corretamente. Para o segundo exemplo, as quatro séries desconectadas foram detectadas (veja a Fig. 3 (b)). No entanto, a saída apresenta um alto nível de ruído, repetido em outras imagens que contêm muitas sequências desconectadas. Além disso, um módulo quebrado, que pode ser identificado por muitos pontos quentes em sua imagem de aIRT, não foi detectado pelo algoritmo (ver a Fig. 3 (d)). Em geral, o método não foi bem-sucedido na detecção de pontos quentes, dado o pequeno conjunto de dados disponível para o treinamento para detectar essa falha.

O algoritmo pôde detectar a maioria das falhas no nível de série e subsérie nas amostras, mas também identificou muitas falhas que não existiam. Gerou assim mais resultados falso-positivos (falhas identificadas incorretamente) do que falso-negativos (falhas que não foram detectadas). Essa é uma conquista importante, pois os falsos positivos podem ser removidos com filtros morfológicos adicionais, ao contrário dos falsos negativos, que são mais prejudiciais.

A CNN também pôde detectar falhas que não foram detectadas anteriormente pelo algoritmo DIP (veja a Fig. 4). A Fig. 4 (a) mostra a imagem de entrada que teve a resposta esperada, fornecida pelas técnicas DIP, mostrada na Fig. 4 (b). A segmentação esperada apresenta a detecção de quatro séries abertas. No entanto, como visto na Fig. 4 (c), a saída da CNN mostra um módulo com uma subsérie desconectada além das quatro séries desconectadas. Esse problema no algoritmo DIP ocorreu porque a falha do módulo era sutil. Além disso, a segmentação das séries desconectadas obtidas

com a CNN foi mais precisa do que a segmentação obtida com o algoritmo DIP. Isso prova a superioridade da rede neural em generalizar e trabalhar em problemas complexos, em diversas condições de imagem.

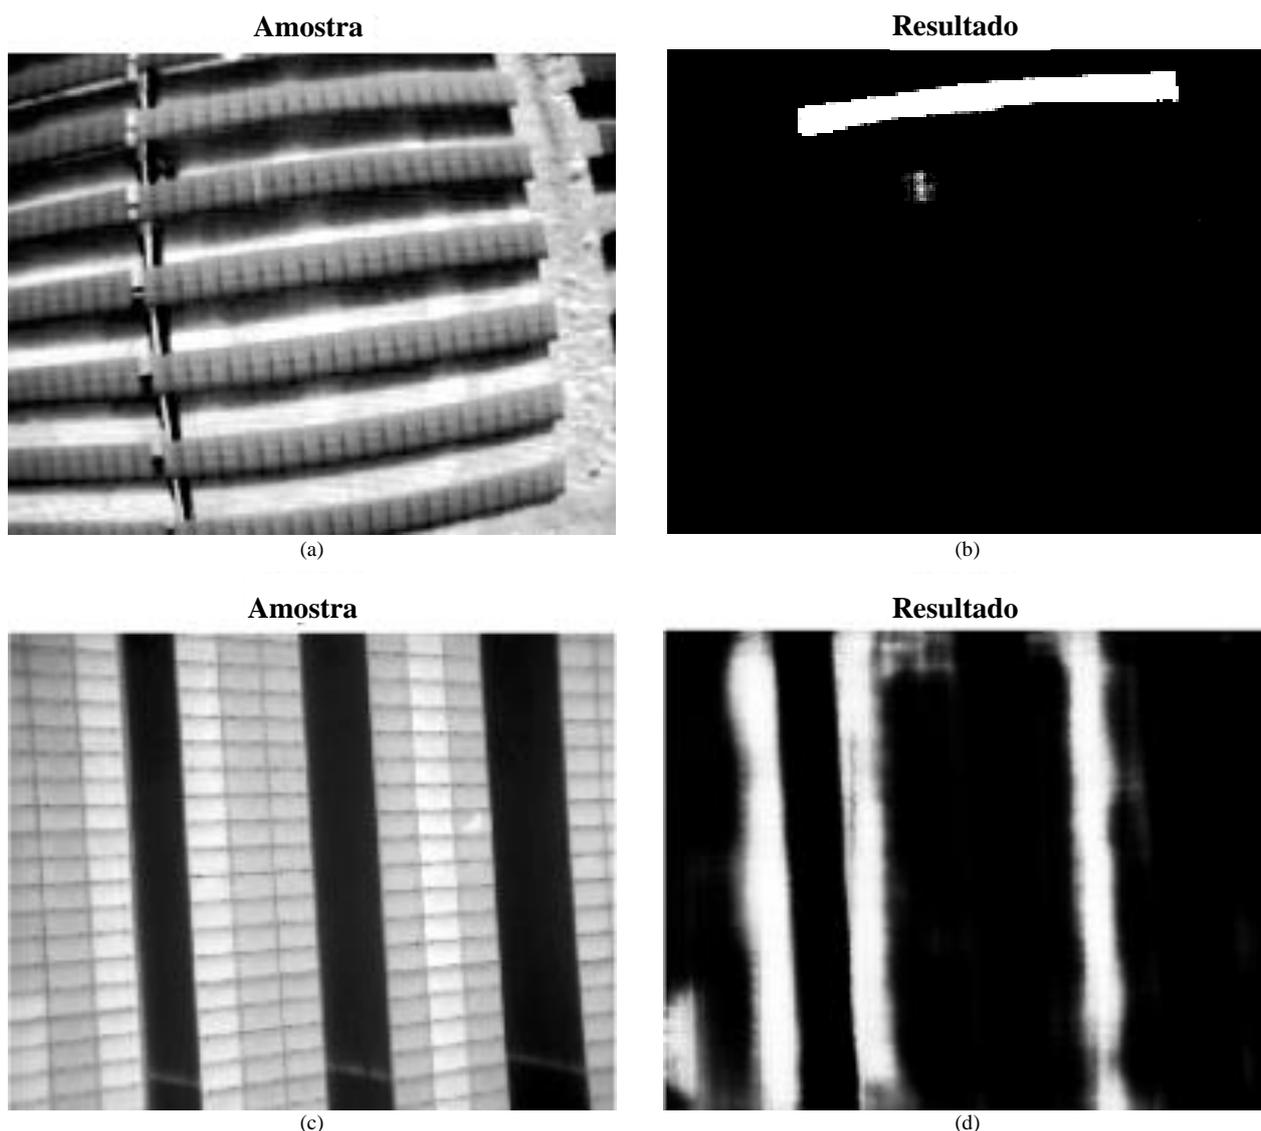


Figura 3 - Dois exemplos de amostras usadas como entrada do algoritmo DIP de segmentação para testes e os resultados obtidos detectando módulos FV com séries desconectadas. (a) imagem aIRT do primeiro exemplo. (b) Resultado do algoritmo para o primeiro exemplo. (c) imagem aIRT do segundo exemplo. (d) Resultado para o segundo exemplo.

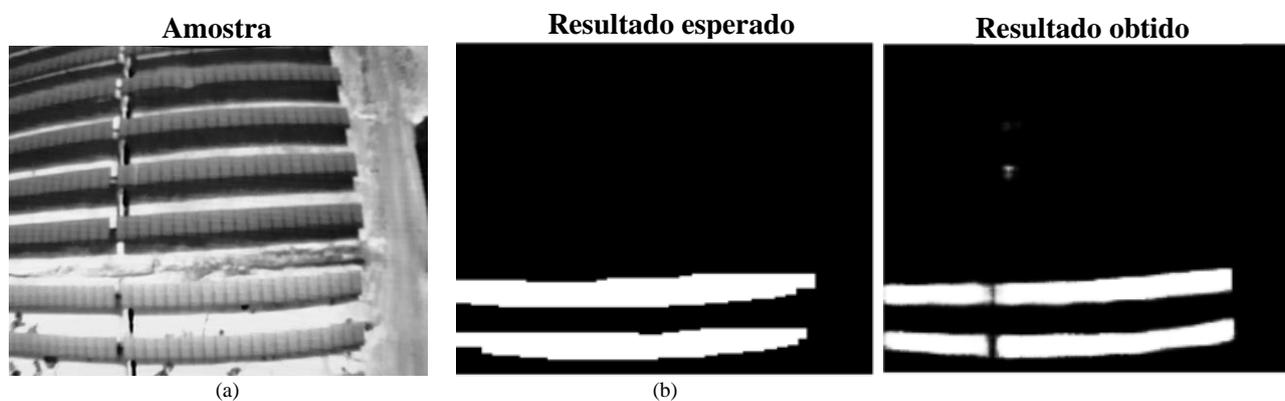


Figura 4 - Exemplo de uma amostra usada para testar o algoritmo CNN. (a) Imagem original, usada como entrada para o modelo. (b) Segmentação esperada da falha, obtida com técnicas DIP. (c) Resultado obtido com o algoritmo de CNN.

#### 4. CONCLUSÕES

Este trabalho apresentou um novo método para detecção e classificação automáticas de falhas em usinas FV empregando aIRT. O método proposto foi bem-sucedido na combinação de técnicas DIP e CNNs, a fim de segmentar corretamente as falhas dos módulos FV e classificá-las em três categorias: subséries desconectados, pontos quentes e séries desconectados. O algoritmo foi eficaz na detecção de falhas mesmo para aquelas que não eram detectáveis com as técnicas DIP. No entanto, gerou diversos falsos positivos, que tiveram que ser filtrados. Os resultados demonstraram que o método é eficaz na detecção e classificação de falhas e é uma etapa importante para a automação completa da inspeção de AIRT.

#### 5 AGRADECIMENTOS

Os autores agradecem à Alexander von Humboldt Foundation pela concessão do Research Linkage Group, que financiou a câmera de infravermelho usada neste trabalho. O Conselho Brasileiro de Pesquisa do CNPq também é reconhecido pelo apoio financeiro, bem como as empresas que permitiram o acesso às usinas FV.

#### REFERÊNCIAS

- Aghaei, M., Grimaccia, F., Gonano, C.A., Leva, S., 2015. Innovative automated control system for PV fields inspection and remote control. *IEEE Trans. Ind. Electron.* 62, 7287–7296.
- Aghaei, M., Quater, P.B., Grimaccia, F., Leva, S., Mussetta, M., 2014. Unmanned Aerial Vehicles in Photovoltaic Systems Monitoring Applications. 29th Eur. Photovolt. Sol. Energy Conf. Exhib. (EU PVSEC 2014) 2734–2739. <https://doi.org/10.1017/CBO9781107415324.004>
- ANEEL, 2019. BIG - Banco de Informações de Geração [WWW Document].
- Arge, F.O.R.L., Mage, C.I., 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition, in: *ICLR 2015*. pp. 1–14.
- Buerhop, C., Schlegel, D., Niess, M., Vodermayr, C., Weißmann, R., Brabec, C.J., 2012. Reliability of IR-imaging of PV-plants under operating conditions. *Sol. Energy Mater. Sol. Cells* 107, 154–164. <https://doi.org/10.1016/j.solmat.2012.07.011>
- de Oliveira, A.K.V., Aghaei, M., Madukanya, U.E., Nascimento, L., Ruther, R., 2018. Aerial Infrared Thermography of a Utility-Scale PV Plant After a Meteorological Tsunami in Brazil, in: 2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC) (A Joint Conference of 45th IEEE PVSC, 28th PVSEC & 34th EU PVSEC). IEEE, Hawaii, pp. 0684–0689. <https://doi.org/10.1109/PVSC.2018.8548019>
- Filho, O.M., Neto, H.V., 1999. Processamento Digital de Imagens, *Revista Brasileira de Geofísica*. <https://doi.org/10.1590/S0102-261X1998000100035>
- Geng, Q., Zhou, Z., Cao, X., 2018. Survey of recent progress in semantic image segmentation with CNNs. *Sci. China Inf. Sci.* 61, 1–18. <https://doi.org/10.1007/s11432-017-9189-6>
- International Electrotechnical Commission, International Electrotechnical Commission (IEC), 2017. IEC TS 62446-3 - Photovoltaic (PV) systems - Requirements for testing, documentation and maintenance - Part 3: Photovoltaic modules and plants - Outdoor infrared thermography.
- John A. Tsanakas, Godefroy Vannier, Alexandre Plissonnier, Duy Long Ha, F.B., 2016. Fault Diagnosis and Classification of Large-Scale Photovoltaic Plants through Aerial Orthophoto Thermal Mapping, in: 31st European Photovoltaic Solar Energy Conference and Exhibition Attached. pp. 1783–1788.
- Kamilaris, A., Prenafeta-Boldú, F.X., 2018. Deep Learning in Agriculture: A Survey. *Comput. Electron. Agric.* 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kim, D., Youn, J., Kim, C., 2017. Automatic fault recognition of photovoltaic modules based on statistical analysis of UAV thermography. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* 42, 179–182. <https://doi.org/10.5194/isprs-archives-XLII-2-W6-179-2017>
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Adv. Neural Inf. Process. Syst.* 1–9. <https://doi.org/http://dx.doi.org/10.1016/j.protcy.2014.09.007>
- Mayo, R.C., Leung, J., 2018. Artificial intelligence and deep learning – Radiology’s next frontier? *Clin. Imaging* 49, 87–88. <https://doi.org/10.1016/j.clinimag.2017.11.007>
- Pierdicca, R., Malinverni, E.S., Piccinini, F., Paolanti, M., Felicetti, A., Zingaretti, P., 2018. Deep convolutional neural network for automatic detection of damaged photovoltaic cells. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* 42, 893–900. <https://doi.org/10.5194/isprs-archives-XLII-2-893-2018>
- Quater, P.B., Grimaccia, F., Leva, S., Mussetta, M., Aghaei, M., 2014. Light Unmanned Aerial Vehicles (UAVs) for cooperative inspection of PV plants. *IEEE J. Photovoltaics* 4, 1107–1113. <https://doi.org/10.1109/JPHOTOV.2014.2323714>
- Rogotis, S., Ioannidis, D., Tsolakis, a, Tzovaras, D., Likothanassis, S., 2014. Early defect diagnosis in installed PV modules exploiting spatio-temporal information from thermal images. *QIRT2014 Conférence*.

- Tsanakas, J.A., Botsaris, P.N., 2012. An infrared thermographic approach as a hot-spot detection tool for photovoltaic modules using image histogram and line profile analysis. *Int. J. Cond. Monit.* 2, 22–30.  
<https://doi.org/10.1784/204764212800028842>
- VATh, 2016. *Electrical Infrared Inspections* ▪ Low Voltage 17.
- Vidal de Oliveira, A.K., Amstad, D., Madukanya, U.E., Rafael, L., Aghaei, M., Rütger, R., 2019. Aerial Infrared Thermography of a CdTe Utility-Scale PV Power Plant, in: 46th IEEE PVSC. Chicago, pp. 1–6.

#### **AUTOMATIC FAULT DETECTION OF PHOTOVOLTAIC ARRAY BY CONVOLUTIONAL NEURAL NETWORKS DURING AERIAL INFRARED THERMOGRAPHY**

**Abstract.** *Aerial Infrared Thermography (IRT) is a non-destructive and cost-effective method for detecting faults in large-scale photovoltaic (PV) power plants. However, the visual assessment of the images captured by aerial IRT, and the analysis of a large number of image frames is very time-consuming. This paper proposes a method for detecting and classifying faults on PV modules, through aerial IRT images, combining Digital Image Processing (DIP) and Convolutional Neural Networks (CNNs) algorithms. With the results obtained so far, the IR images acquired were successfully processed with DIP techniques to detect the faults of PV modules in the power plant that are used as samples for training the CNN. The developed neural network algorithm can detect faults on the aIRT images and classify them in three categories: disconnected substrings, hot spots, and disconnected strings. The results have demonstrated that the method is effective in detecting and classifying faults, and it is an important step for the full automation of aIRT inspection.*

**Key words:** System Performance, Monitoring, Artificial Intelligence.