

LOCALIZAÇÃO DE AVARIAS EM MÓDULOS FOTOVOLTAICOS POR MEIO DE PROCESSAMENTO DE IMAGENS TERMOGRÁFICAS

VICTOR DYRJAWOJ

outubro de 2025

LOCALIZAÇÃO DE AVARIAS EM MÓDULOS FOTOVOLTAICOS POR MEIO DE PROCESSAMENTO DE IMAGENS TERMOGRÁFICAS

Victor Dyrjawoj - 1240354@isep.ipp.pt

**Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica – Sistemas Elétricos de Energia**

**Orientador: Prof.Dr. Manuel Carlos Malheiro de Carvalho Felgueiras -
mcf@isep.ipp.pt**

Co-orientador: Prof.Dr. Luiz Henrique Alves Monteiro - luizm@mackenzie.br

Júri:

Presidente:

Prof.Dr. Fernando Mauricio Teixeira De Sousa Dias

Vogais:

Prof.Dr. Filipe Alexandre de Sousa Pereira

Prof.Dr. Manuel Carlos Malheiro de Carvalho Felgueiras

Prof.Dr. Luiz Henrique Alves Monteiro

Prof.Dr. Rogério Issamu Yamamoto

Dedicatória

Dedico este trabalho aos meus pais Elisabeth Walujko Dyrjawoj e Nicolau Dyrjawoj.

Resumo

O número de centrais fotovoltaicas deverá aumentar nos próximos anos, novas instalações de pequeno e grande porte faram parte do sistema elétrico mundial. Contudo, é necessário ressaltar a importância de verificações periódicas e manutenções preventivas dos equipamentos, já que são susceptíveis a diversos fenômenos que os prejudicam e acabam por diminuir a eficiência da produção de energia. Sendo assim, métodos para localizar avarias são essenciais para a manutenção e produtividade dos módulos fotovoltaicos. Destaca-se a análise por termografias, pois se trata de um método não invasivo que é capaz de mostrar regiões com possíveis danos ao equipamento, conhecidos como *hotspots*. No entanto, as imagens térmicas por si só não são capazes de satisfazer por completo a inspeção, porque são afetadas por diversos fenômenos. Logo, técnicas auxiliares tais como processamento e segmentação de imagens são implementadas junto as termografias, são um auxiliar precioso, possibilitando detectar bordas, filtrar ruídos e outros. Deste modo, este trabalho endereça parcialmente aquele objetivo e propõe um procedimento computacional que utilizou algumas técnicas de processamento e reconhecimento de imagens para localizar avarias em cima de módulos fotovoltaicos. Os resultados obtidos resultaram na criação de um *dataset* de termografias de módulos, treinamento de uma rede neural modelo Yolov8 com a precisão de 95% para detecção de bordas e capacidade de localizar as avarias em módulos reais testados por sobreposição de imagens e coordenadas.

Palavras-chave: Avarias. Espaço de Cor HSV. Módulo fotovoltaico. Processamento de imagens. Termografias. Yolov8.

Abstract

The number of photovoltaic plants is expected to increase in the coming years, new installations of small and large sizes are part of the world's electricity system. However, it is necessary to emphasize the importance of periodic checks and preventive maintenance of equipment, since they are susceptible to various phenomena that harm them and end up reducing the efficiency of energy production. Therefore, methods to locate malfunctions are essential for the maintenance and productivity of photovoltaic modules. Thermography analysis stands out, as it is a non-invasive method that can show regions with possible damage to the equipment, known as *hotspots*. However, thermal images alone are not able to completely satisfy the inspection, because they are affected by various phenomena. Therefore, auxiliary techniques such as image processing and segmentation are implemented along with thermography, they are a precious aid, making it possible to detect edges, filter noise and others. Thus, this work partially addresses that objective and proposes a computational procedure that used some techniques of image processing and recognition to locate malfunctions on top of photovoltaic modules. The results obtained resulted in the creation of a *dataset* of thermographies of modules, training of a YOLOv8 neural network model with 95% accuracy for edge detection, and the ability to locate the malfunctions in real modules tested by superimposing images, and coordinates.

Keywords: Faults. HSV Color Space. Photovoltaic Module. Image Processing. Thermography. YOLOv8.

Agradecimentos

Várias pessoas e instituições contribuíram directa ou indirectamente para a efectivação deste trabalho e gostaria de aqui lhes exprimir os meus agradecimentos.

O primeiro agradecimento será para minha família, minha mãe Elisabeth Walujko Dyrjawoj e meu pai Nicolau Dyrjawoj, que me apoiaram em todo momento na graduação, na pós-graduação, durante minha viagem a Portugal e por todo esforço em minha criação que levou a este trabalho.

Ao meu caro amigo e orientador Prof. Dr. Manuel Carlos Malheiro de Carvalho Felgueiras, pelas excelentes reflexões técnicas e questionamentos que levaram resultados para a confecção deste trabalho. Seu apoio foi fundamental para que se trilhasse o caminho para a conclusão deste trabalho.

Ao meu caro amigo e orientador do Trabalho de Conclusão de Curso para a graduação em Engenharia Elétrica, Prof. Dr. Luiz Henrique Alves Monteiro, pelos momentos de reflexão, instigação de desenvolvimento de ideias, conselhos, revisão e a imensurável ajuda com as técnicas que se aplicaram a este trabalho.

Ao Prof. Dr. Rogério Yamamoto pela ajuda com a revisão do trabalho e seus conselhos que formalizaram uma linha de raciocínio que foram utilizadas durante a escrita deste documento.

Aos coordenadores Prof. Dr. Bruno Luis Soares Lima, da Engenharia Elétrica e ao Prof. Dr. Nelson Maestrelli, da Engenharia Mecânica, pela disponibilidade e pelo fornecimento de equipamentos para os testes deste trabalho.

Ao estagiário Rafael Rego dos Santos Caldeira pela assistência durante a captura das termografias e auxílio na montagem do *setup* de testes dos módulos fotovoltaicos.

As instituições de ensino superior Instituto Politécnico do Porto e a Universidade Presbiteriana Mackenzie pelo programa de dupla titulação que possibilitou meu intercâmbio em Portugal.

Índice

1	Introdução	14
1.1	Problema da Pesquisa	14
1.2	Objetivo Geral	16
1.3	Objetivos Específicos	16
1.4	Justificativa	16
2	Revisão da Literatura.....	18
2.1	Energia Solar Fotovoltaica	18
2.1.1	Efeito e Células Fotovoltaicas	18
2.1.2	Avárias em cima de Módulos Fotovoltaicos	19
2.2	Termografias e Observação de Avárias.....	21
2.3	Processamento e Segmentação de Imagens	22
2.3.1	Técnicas e Operações aplicadas aos estudos e análises de imagens	22
2.3.2	Reconhecimento e Detecção de Objetos	22
2.3.3	Filtro Gaussiano em Imagens	24
2.3.4	Segmentação por Espaço de Cor	25
2.3.5	Transformações Morfológicas	25
3	Metodologia	27
3.1	Procedimentos do Trabalho.....	27
3.2	Setup de Testes	29
3.3	Registro Termográfico e Coleta de Imagens.....	32
3.4	Criação e Preparação do <i>Dataset</i>	34
3.5	Treinamento da Rede Neural	35
3.6	Filtro Gaussiano, Segmentação por <i>Thresholding</i> de Espaço de Cor e Processamento Morfológico.....	37
3.6.1	Filtro Gaussiano	37
3.6.2	Segmentação por <i>Threshold</i> de Espaço de Cor.....	38
3.7	Demarcação e Localização.....	42
4	Resultados e Discussões.....	45
4.1	Coleta de Informações e Termografias do setup de teste.....	45
4.2	Resultados dos Treinamento da Rede Neural e Detecção dos Módulos nas Termografias.....	47
4.3	Efeitos do Filtro Gaussiano	50
4.4	Valores do Threshold de Espaço de Cor - HSV.....	52

4.5	Melhorias com as Transformações Morfológicas	54
4.6	Demarcação das Avarias em relação as Imagens Originais	56
4.7	Avarias Localizadas em cima dos Módulos Fotovoltaicos	58
5	Conclusão	61
6	Referências.....	63

Lista de Figuras

Figura 1 Corte da célula e o efeito fotovoltaica.....	19
Figura 2 Exemplo de duas <i>strings</i> com diferenças de produção de energia baseada na integridade dos módulos.	20
Figura 3 Etapas da metodologia do Trabalho	29
Figura 4 Valores das medições de Tensão de circuito aberto de cada equipamento. Os valores da esquerda para direita são 35.03, 34.95, 33.6 Vdc.....	30
Figura 5 Camadas de fita isolante colocadas sobre os módulos fotovoltaicos para emular avarias.	31
Figura 6 Esquemático do Setup de Teste. Os retângulos em preto representam as camadas de fita isolantes e sua disposição em cima de cada painel.....	32
Figura 7 Fotografia da disposição dos módulos fotovoltaicos no local da realização do trabalho.....	32
Figura 8 Amostra da termografia registrada dos módulos.....	33
Figura 9 Coletânea de imagens registradas	33
Figura 10 Marcações das posições para identificar os módulos fotovoltaicos nas imagens no MakeSense.....	35
Figura 11 Processo de Reconhecimento, Detecção e Aplicação da Máscara de cor Branca.....	37
Figura 12 Aplicação do Filtro Gaussiano em imagens térmicas dos módulos fotovoltaicos.....	38
Figura 13 Valores dos Espaços de cor dos painéis em HSV.....	39
Figura 14 Ajuste de <i>threshold</i> baseado nos valores do histograma de saturação.....	40
Figura 15 Máscara binária aplicada à imagem após o <i>threshold</i>	40
Figura 16 Abertura binária: antes e depois da aplicação.....	42
Figura 17 Fechamento binário: antes e depois da aplicação.....	42
Figura 18 Exemplo de áreas dos módulos segmentadas sobrepostas à imagem original.....	43
Figura 19 Demarcação dos com pixels maior intensidade de cor, representando os pontos de calor.....	44
Figura 20 Valores da queda de tensão gerada pelos módulos durante os captura de imagens térmicas.....	46
Figura 21 Verificação da temperatura das fitas isolantes em relação ao restante dos módulos	47
Figura 22 Gráficos da evolução das métricas durante o treinamento.....	48
Figura 23 Segmentação por <i>Threshold</i> de espaço de cor HSV sem e com o filtro gaussiano $x = 5$, $y = 5$, $\sigma = 10$	50
Figura 24 Aplicação do Filtro Gaussiano de acordo com a Tabela 3.....	51
Figura 25 Variação dos histogramas da imagem	52
Figura 26 Histograma com os picos da saturação.....	53
Figura 27 Histograma da Saturação no <i>hotspot</i>	53
Figura 28 Melhoria dos aspectos das regiões segmentadas com o fechamento binário	55
Figura 29 Diminuição de regiões com poucos pixels e eliminação da borda do painel após a abertura binária	56

Figura 30 As camadas registradas colocadas sobre a imagem original.	57
Figura 31 Avarias sobrepostas à imagem original.....	57
Figura 32 Localização das avarias nos módulos.	58
Figura 33 Análise das avarias no painel fotovoltaico da direita.....	59
Figura 34 Análise das avarias no painel fotovoltaico do meio.....	59
Figura 35 Análise das avarias no painel fotovoltaico da esquerda	59

Lista de Tabelas

Tabela 1 Parâmetros usados no ambiente do Google Colab.	35
Tabela 2 Parâmetros de treinamento do Yolov8.	36
Tabela 3 Valores dos Elementos para cada aplicação do Filtro Gaussiano.	38
Tabela 4 Valores do Kernel utilizados para ambas transformadas morfológicas.	41
Tabela 5 Valores das métricas de qualidade obtidos ao final do treinamento.	48
Tabela 6 Imagens dos módulos detectados para o teste - 100 epochs	49
Tabela 7 Valores do filtro do espaço de cor HSV	53

Lista de Acrónimos e Lista de Símbolos

Lista de Acrónimos

TP	True Positive
FP	False Positive
FN	False Negative
RGB	Red, Green, Blue
HSV	Hue, Saturation, Value
Vdc	Voltage Direct Current

Lista de Símbolos

x	Coordenada no eixo das abscissas
y	Coordenada no eixo das ordenadas
σ	Desvio padrão

1 Introdução

1.1 Problema da Pesquisa

Atualmente, a energia solar fotovoltaica é marcada como uma fonte chave para o desenvolvimento sustentável que pretende atingir as metas de acordos globais que visam a diminuição das emissões líquidas de carbono até 2050, NET-ZERO 2050 (IEA, 2024). Dentre as existentes fontes renováveis, destaca-se a solar fotovoltaica devido as projeções de crescimento que mostram que esta apresentará maior crescimento os próximos anos (IEA, 2024). A ampliação do setor solar está associada a políticas públicas incentivo, redução do custo de produção dos módulos e a facilidade de instalação, fator que possibilitou o uso em nível residencial e industrial.

O avanço do setor mostra um entusiasmo com esta tecnologia, entretanto é necessário entender que por mais que ela se mostre versátil e financeiramente econômica, os módulos fotovoltaicos são suscetíveis a falhas decorrentes das intempéries da natureza, acidentes na etapa da montagem dos equipamentos e defeitos de fabricação. Constata-se que os módulos são relativamente frágeis, especialmente sua superfície, responsável pela geração de energia e o local mais afetado. Logo, ao estarem em contato com elementos que as prejudiquem, a eficiência dos painéis diminui, assim altera a produção de energia que causa quedas e perdas na produção. Portanto, o contexto que se encontram torna-se imprescindível localizar as avarias presentes em cima dos painéis, tendo em vista que para manter o sistema a funcionar com o melhor desempenho desejado (Rubanenko *et al.*, 2024).

A avaliação dos equipamentos com o objetivo de identificar se estes estão avariados ou não, possui abordagens diversas que seguem caminhos diferentes. Ao analisar o comportamento de curvas I-V, correspondentes a tensão e corrente de saída dos painéis, com o propósito de verificar desvios dos valores de potência produzida durante determinado período (Hocaoglu *et al.*, no date) compara-se os gráficos de cada equipamento. A aquisição das informações para estas curvas requer tempo e necessita pausar a produção de energia, logo constitui-se em um método ativo, que causa impacto na produção de energia. Em contrapartida, a verificação do perfil térmico dos equipamentos com o auxílio de uma câmera térmica é uma alternativa passiva, pois não interrompe o sistema, ou seja, não há impacto no funcionamento. Baseia-se

no conceito que avarias em cima dos módulos fotovoltaicos causam dissipação de energia em forma térmica ao invés de elétrica, assim aquecem o ponto onde se encontram, chamados de *hotspots* (De Oliveira *et al.*, 2021). Logo, quando se é necessário manter a central a funcionar e fazer inspeções passivas, a termografia mostra-se ser a melhor alternativa. Nesse quadro, as termografias são amplamente utilizadas, aplicadas em centrais de pequeno, médio e grande porte, encontram-se junto a drones que percorrem diversos equipamentos ao mesmo tempo, como também junto a técnicos e operadores para instalações menores (Zefri *et al.*, 2022).

Por mais que as termografias mostrem os pontos quentes, vale ressaltar que não só os módulos fotovoltaicos são capturados, como também o cenário ao redor que possui suas características térmicas o que tem potencial de interferir na leitura, efeitos como difusão térmica e óptica no momento da captura são responsáveis por gerar erros nas imagens (Xu *et al.*, 2021). Portanto, técnicas auxiliares para diminuir as distorções que as imagens térmicas geram junto a falta de demarcações os módulos avariados, torna-se necessário o emprego de técnicas auxiliares para preencher estas lacunas.

Repare-se que a há limitações quanto a métodos manuais e visuais de inspeção, por exemplo, em centrais fotovoltaicas de grande e médio porte são um desafio para realização destas tarefas, pois necessitariam de muito tempo para serem completadas e são influenciadas pela expertise dos operados locais. Por isso, um sistema que use técnicas de visão computacional representa uma melhora na qualidade dos monitoramentos com possibilidade de automatização dos sistemas.

Técnicas computacionais de imagens são numerosas e propõem analisar determinadas características de imagens com base nos algoritmos empregados. Diversas propostas são abordadas na literatura quando ao processamento de termografias de módulos fotovoltaicos, as finalidades e métodos não divergem quanto ao propósito final, demarcar os pontos quentes em cima dos painéis. Os trabalhos de (Afifah *et al.*, 2020) aplicaram algoritmos de segmentação que avaliavam os valores dos pixels e de histogramas das imagens para se encontrar qual representavam *hotspots*. Métodos semelhantes são trabalhados com algoritmos de detecção de bordas, que visam montar uma área segura onde se verifica problemas nos equipamentos, como visto em (Montanez *et al.*, 2020). A aplicação de filtros de remoção de ruídos mostrou-se ser um campo valorizado, pois permite eliminar falhas das capturas de imagens (Chen *et al.*, 2023). A abordagem da detecção de *hotspots* com o uso de inteligência artificial e redes neurais é amplamente estudada e trabalhada (Tajwar *et al.*, 2021), contudo dependem de uma quantidade extraordinária de imagens térmicas para realizarem seus treinamentos e sofrem com registros, detecções erradas dado o ambiente das centrais. Um direcionamento também abordado é a demarcação dos pontos quentes através de sobreposição de imagens, o que permite mostrar a localização das avarias visto em (De Oliveira *et al.*, 2021).

Portanto, os métodos de processamento e segmentação de imagens podem ser usados como técnicas auxiliares as termografias, assim as complementam. Apresentam mesmo a vantagem e oportunidade de melhoria destas técnicas, adaptando-as com o benefício que cada uma pode oferecer, a fim de que se monte um processo capaz de localizar as avarias nos módulos fotovoltaicos com maior precisão e que se proteja contra erros. Sendo assim, este trabalho pretende criar um procedimento computacional capaz de aplicar técnicas de segmentação,

processamento de imagens de forma que se complementem e localizem defeitos em cima de módulos fotovoltaicos.

1.2 Objetivo Geral

O objetivo deste trabalho é localizar avarias em cima de módulos fotovoltaicos por meio de técnicas de detecção, processamento e segmentação de imagens em termografias para que sejam demarcados os pontos que indicam defeitos. Para tal programa mostrar sua eficiência, deverão ser registradas termografias de painéis que possuam algum tipo de avaria, com o propósito de ele seja capaz de fazer marcações ao redor da área dos pontos onde possa haver anormalidades de prejudiquem os equipamentos, assim a validar as marcações feitas pelos algoritmos.

1.3 Objetivos Específicos

A fim de que a proposta deste trabalho seja alcançada, torna-se necessário atingir certos objetivos específicos. As etapas citadas devem estar de acordo com procedimentos de coleta e processamento de imagens que provem a eficiência do método. Portanto, esses objetivos tratam da parte de coleta de imagens, treinamento de uma rede neural que seja capaz de reconhecer os equipamentos, aplicação de técnicas de segmentação e de processamento de imagens para separar os pontos quentes e demarcá-los nas imagens. Assim, as metas específicas são:

- Montar um *setup* de teste com módulos e emular avarias em cima dos equipamentos ;
- Criar uma base de dados (*dataset*) com imagens térmicas de módulos fotovoltaicos ;
- Usar uma rede neural que seja capaz de reconhecer módulos fotovoltaicos em termografias ;
- Separar e demarcar os *hotspots* com técnicas de processamento e segmentação de imagens ;
- Validar o método desenvolvido em módulos fotovoltaicos reais e localizar suas avarias.

1.4 Justificativa

A crescente procura por fontes renováveis e os investimentos no setor energético são os fatores responsáveis do desenvolvimento e instalação de novas centrais fotovoltaicas em todo o mundo. A magnitude destas novas usinas é muito variável, devido a versatilidade e a relativa fácil implementação para sistema *on-grid* e *off-grid* , logo a gama de usuários podem ser de nível de geração e transmissão, quanto de nível de distribuição, consumidores residenciais e comerciais que desejam produzir sua própria energia. Portanto, para que se tenha a operação com máxima eficiência de produção em uma central fotovoltaica, é necessário que todos os módulos fotovoltaicos estejam funcionando corretamente a todo momento. No entanto, devido a um

conjunto de imponderáveis tais como a intempéries do tempo, sombreamentos, microfissuras, falhas em equipamentos, entre outros, os painéis sofrem avarias que prejudicam o circuito que estão ligados decorrendo assim a natural queda da produção. Desta forma, o melhor estado é apenas alcançado quando são feitas manutenções preventivas, as quais corrigem mal funcionamentos e evitam a aumento de avarias, trazendo benefícios econômicos ao longo prazo.

Localizar essas avarias é um verdadeiro desafio que se estuda a muito tempo, e diversas técnicas foram propostas, porém a que melhor apresenta resultados é que decorre da utilização e processamento de imagens térmicas. Por se tratar de um método passivo, não há a necessidade de desconectar a usina da rede para o procedimento, como também é um método rápido que verifica o perfil térmico do equipamento. Todavia, a termografia por si só sofre influências, de difusão ótica e térmica o que prejudicam sua leitura e a interpretação das imagens, consequentemente, necessita de ferramentas computacionais de processamento e segmentação para que possam ajudar a identificar avarias nos módulos.

Diversas técnicas são aplicadas para localizar avarias em formas de *hotspots* que abrangem detecção de bordas, segmentação com máscaras binárias para separar partes dos equipamentos, aplicação de filtros com intuito de eliminação de ruídos, operações morfológicas para processamento dos aspectos dos elementos em estudo e também modelos de redes neurais que buscam identificar elementos chave nas termografias. Portanto, a aplicação de procedimentos que sejam capazes de unificar todos essas técnicas, de forma que consiga demarcar e localizar as avarias constitui um avanço tecnológico neste setor.

A metodologia e os procedimentos computacionais propostos neste trabalho visam em beneficiar pequenas instalações fotovoltaicas que estão com problema de eficiência, como também grandes centrais que necessitam de drones para monitoramento de seus equipamentos pois, com o uso desse procedimento, podem-se localizar e demarcar possíveis avarias em seus sistemas.

O presente trabalho possuiu sua inovação na proposição de uma metodologia que seja capaz de unificar técnicas de processamento e segmentação de imagens em termografias de módulos fotovoltaicos, a fim de que possa servir como base para detecção e localização de avarias, de forma a facilitar a realização de restaurações, assim a reduzir prejuízos financeiros e perdas de produção de energia.

2 Revisão da Literatura

2.1 Energia Solar Fotovoltaica

2.1.1 Efeito e Células Fotovoltaicas

O princípio do funcionamento de centrais fotovoltaicas baseia-se no efeito fotovoltaico. Semicondutores liberam elétrons de suas camadas de valência quando recebem energia da luz solar, proveniente da interação da radiação eletromagnética com os estes materiais. A energia absorvida da luz é mais do que o suficiente para que os elétrons se desprendam, o que gera uma diferença de potencial na ponta da estrutura, logo há a um fluxo de corrente elétrica, (Kazmerski, Kurtz and Vasi, 2024).

Os materiais semicondutores possuem características benéficas para o amplo uso no setor da engenharia elétrica e eletrônica, neste caso, para a produção de células fotovoltaicas, a menor parcela de um painel, é utilizado o silício dopado tipo P-N. O material nesta condição, junto a luz solar, gera uma diferença de potencial entre os silícios proveniente da movimentação de elétrons da camada de valência da região tipo N para a tipo P que possui lacunas abertas a serem preenchidas (Packa *et al.*, 2016). A fim de manter esse fluxo de elétrons de forma contínua que possa ser usado como uma fonte geradora de energia, o material semicondutor é envolvido com estruturas metálicas parecidas com grades, logo os elétrons passam através delas para o outro lado. Para complementar, como estes materiais vão estar em um ambiente aberto e para garantir a melhor absorção de luz solar, são necessários utilizar películas protetoras em cima, como matérias antirreflexivos transparente, o que permite converter uma quantidade maior de

luz em energia (Kazmerski, Kurtz and Vasi, 2024) (Packa *et al.*, 2016) A Figura 1 mostra o funcionamento de uma célula fotovoltaica cortada ao meio.




Figura 1 Corte da célula e o efeito fotovoltaico.

2.1.2 Avarias em cima de Módulos Fotovoltaicos

Os módulos fotovoltaicos são um conjunto de células ligadas em série e/ou em paralelo que somam as correntes e tensões produzidas, logo permite produzir uma quantidade de corrente maior em comparação a uma célula isolada. Um conjunto desses módulos, quando conectados de forma semelhante, formam uma cadeia (*string*) com o mesmo intuito anteriormente descrito, capazes de somar as capacidades e aumentar a produção energética.

Como mencionado no item 2.1.1, o funcionamento desses equipamentos depende da incidência de radiação sob a superfície das células. Portanto, todo fator que prejudica a incidência de luz ou que degrade a célula, afeta a produção de energia. Dentre os fatores que prejudicam essa incidência, destacam-se sombreamentos, sujeiras e objetos em cima dos painéis como sendo obstruções passivas de relativa fácil remoção, visto que basta limpar o equipamento ou mudá-lo de posição. Danos físicos como rachaduras, trincas, fendas e rompimento das células também afetam a eficiência desses equipamentos, estes atuam de forma ativa, pois prejudicam a estrutura do módulo e interrompem parcialmente o fluxo de corrente, logo necessitam de uma atenção e manutenção mais ativa (Abdelsattar, Abdelmoety and Emad-Eldeen, 2023).

Fundamentalmente a célula fotovoltaica funciona como uma fonte de corrente contínua que produz uma tensão em seus polos devido a diferença de potencial, logo conectadas em série com intuito de aumentar a produção a partir da soma das correntes. Em uma situação na qual

uma ou mais dessas células deixa fornecer corrente, ela se torna uma carga neste circuito, o que diminui a tensão e por efeito Joule aquecem a localidade. Portanto, quando ocorrem esses problemas com os módulos, os equipamentos reduzem a produção de energia elétrica, que passa a ser dissipada em forma de calor, levando à formação de um ponto quente ou *hotspot*.

Além do módulo prejudicado, outros painéis da cadeia também podem apresentar queda na produção. Logo, um painel avariado é capaz de prejudicar o conjunto e afetar a produção de energia como um todo. Portanto, é necessário identificá-los e localizá-los para manter a boa operação, utilizando, por exemplo, câmeras térmicas (Chattopadhyay *et al.*, 2018). Quando o ponto quente é localizado, pode-se identificar o fator responsável e aplicar as devidas correções. A Figura 2 esquematiza a diferença de produção de duas cadeias nas mesmas condições, porém com um módulo avariado em uma delas.

A literatura também cita outros problemas em cima de módulos fotovoltaicos que criam pontos quentes, tais como *diodos de by-pass*, os quais servem para diminuir os efeitos do sombreamento como visto em (Abdelsattar, Abdelmoety and Emad-Eldeen, 2023). Outro problema que causa *hotspots* são as microfissuras originadas durante a fabricação, ou instalação dos equipamentos, por se tratar de defeitos muito pequenos, não são capazes de serem vistos em inspeções visuais, apenas com câmeras térmicas (Xu, Zhou and Fei, 2014).

Portanto, inspeções e manutenções preventivas se mostram necessárias para a preservação do sistema e que o mantenha a funcionar de forma eficiente, o que torna necessário a aplicação de métodos que sejam capazes de demarcar e localizar esse tipo de avaria em módulos fotovoltaicos. A partir destas informações, medidas preventivas são aplicadas para minimizar os impactos nos equipamentos e a continua produção de energia. A Figura 2 mostra a visão ampliada de como um módulo avariado influencia no sistema.




Figura 2 Exemplo de duas *strings* com diferenças de produção de energia baseada na integridade dos módulos.

2.2 Termografias e Observação de Avarias

A termografia tem sido aplicada em diversas áreas das ciências e é comumente usada nas engenharias. Trata-se de um processo não invasivo de análise da temperatura de um objeto e amplamente utilizada no setor fotovoltaico, pois possibilita observar os equipamentos com focos de calor de forma indireta e sem a necessidade de removê-los de operação (Chattopadhyay *et al.*, 2018).

Esse método se baseia na Lei de Planck, a qual estabelece que todos os corpos que estão acima do zero absoluto, ou seja, 0K, emitem radiação infravermelha proporcional à sua temperatura (Islam *et al.*, 2019) Com base nesse conceito, foi possível desenvolver equipamentos que convertem radiação em um valor de temperatura proporcional. Os instrumentos de detecção possuem sensores que capturam comprimentos de onda entre 0,75 μm e 14 μm , que é a faixa do espectro eletromagnético correspondente ao infravermelho, dada a intensidade capturada, é proporcional a uma temperatura, assim sendo possível saber qual é a temperatura daquele corpo ou objeto (Glavaš *et al.*, 2017).

As câmeras térmicas convertem a radiação infravermelha em sinais digitais que são processadas e formam imagens que representam os valores de temperatura dos objetos por meio de variações de tons de cores. Esses instrumentos possuem sensores que medem a radiação eletromagnética dentro da faixa do infravermelho, há também exemplares que contêm câmeras digitais para registro fotográfico para fins de análise comparativa. Os valores obtidos são convertidos em temperatura e sua disposição forma a imagem com o perfil térmico do cenário (Ngo and Macabebe, 2017).

A aplicação desta técnica no cenário de instalações fotovoltaicas situa-se na observação de avarias nos módulos fotovoltaicos, pois trata-se de um método mais eficiente e não invasivo. Sob os painéis pode-se encontrar diversos problemas tais como microfissuras, células queimadas e outros que causam uma dissipação de energia em forma de calor pois estão a atuar como resistências no circuito. A observação deste fenômeno é eficazmente feita com a câmeras térmicas, pois é um método rápido e seguro (Packa *et al.*, 2016) .

A inspeção das termografias dos módulos, são feitas por técnicos ou por câmeras acopladas a drones de observação que sobrevoam a instalação em busca de pontos quentes, ambos os meios têm a finalidade de buscar avarias e realizar manutenções preventivas, visto que os painéis já estão em operação em um local aberto (Glavaš *et al.*, 2017) . Além desta forma de verificação, há também a observação termográfica em módulos para teste de fábrica, os quais são injetados uma corrente elétrica controlada para garantir que não há células queimadas, trincadas ou com alguma outra forma de defeito, neste caso uma câmera é apontada para o equipamento em um local fechado e controlado (Islam *et al.*, 2019).

2.3 Processamento e Segmentação de Imagens

2.3.1 Técnicas e Operações aplicadas aos estudos e análises de imagens

Imagens contêm uma grande quantidade de informações que auxiliam nos estudos e pesquisas em diversas áreas. Ao modificá-las, separar regiões e analisar valores contidas nelas, pretende-se buscar dados que enriqueçam pesquisas. Das técnicas existentes, podem-se destacar a classificação de Imagens com uso de redes neurais, segmentação por valores dos espaços de cores, contorno de bordas e processamentos que modificam a imagem. Nos próximos itens serão abordados os temas de reconhecimento de objetos item 2.3.2, processamentos itens 2.3.3 e 2.3.5 e segmentação por espaço de cor no item 2.3.4.

2.3.2 Reconhecimento e Detecção de Objetos

O reconhecimento e a detecção de objetos são feitos através de técnicas de visão computacional que buscam determinadas características para a classificação e realização da tarefa, frequentemente aplicadas junto a redes neurais convolucionais (Liu and Song, 2024). Estas redes em especial são classificadas como *Deep-Learning's* para análise e processamento de grandes quantidades de informações, como por exemplo imagens, o que auxilia nas tarefas de reconhecimento e detecção de objetos (Alqahtani, Almutared and Alzahrani, 2023). Composta de diversas camadas de máscaras, responsáveis por aplicar operações de segmentação e filtros nos dados a fim de detectar padrões tais como bordas, formas e texturas, de forma a possibilitar o reconhecimento de imagens, (Phan and Nguyen, 2023).

Dentre os modelos existentes de redes neurais convolucionais, a literatura comumente cita o YOLOv8 (Liu *et al.*, 2025), trata-se de uma arquitetura *single-stage* (realiza a detecção e a classificação simultaneamente) *open-source*, relativa baixa necessidade computacional, rápida, flexível e que requer uma quantidade menor de imagens para a tarefa, (Mazen, Seoud and Shaker, 2023). O Yolov8 é codificado em Python e possui modelos internos realizam tarefas de detecções por *bounding-boxes* e segmentações instantâneas por máscaras ao redor de objetos em imagens estáticas ou em vídeos (Gargouri and Haddeji, 2024). A aplicação deste modelo é útil para análise de módulos fotovoltaicos em usinas pequenas, pois será utilizado junto a um técnico, como também a uma instalação de maior escala com auxílio de drones com câmeras de monitoramento. A velocidade de seu treinamento é maior quando comparada a outras redes neurais. Adicionalmente, essa rede consegue realizar a detecção com boa eficiência utilizando relativamente poucas imagens para seu treinamento (YANG *et al.*, 2021). O treinamento desta rede neural pode utilizar de dados anotados dos *dataset* que são rotulados aos objetos de interesse a serem identificados, o que auxilia no treinamento, pois utilizam de pesos baseado nas informações previamente disponibilizadas (Zhao *et al.*, 2025).

A avaliação da qualidade do modelo proposto é feita analisando quatro métricas de desempenho:

1. *Precision* (valor de detecções corretas feitas) a qual relaciona os valores de Verdadeiros Positivos em relação a Falsos Positivos, Equação 01;

$$PRECISION = \frac{TP}{TP + FP} \quad (1)$$

2. *Recall* (capacidade de detectar objetos presentes) a qual relaciona os valores de Verdadeiros Positivos em relação a Falsos Negativos, Equação 02;

$$RECALL = \frac{TP}{TP + FN} \quad (2)$$

3. *mean Average Precision* (mAP, precisão média das predições) a qual é a média da área dos gráficos de valores da *Precision* em relação a *Recall* , Equação 03;

$$AP = \int_0^1 P dR$$

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (3)$$

4. *mean Average Precision 50-95* (mAP50-95, precisão geral do modelo) a qual é a média dos valores de *mAP*, Equação 04.

$$mAP_{50-95} = \frac{1}{n} \sum_{k=1}^{k=n} mAP_k \quad (4)$$

As métricas são responsáveis por descrever a qualidade do treinamento, pois quanto mais próximas de 1 estão, significa que houve um bom treinamento (Wang *et al.*, 2024) . Também é necessário verificar o comportamento dos gráficos, pois caso ocorrer uma diminuição destes valores ou que permaneçam por determinado período estagnados, constará que a de neural não está a desempenhar o papel de reconhecer corretamente as imagens e está em um estado de *overfitting*. O fenômeno pode ser verificado quando testado em imagens que não fizeram parte do treinamento, caso os resultados de forem muito divergentes consta-se que o modelo treinado está com problemas.

Modelos de reconhecimento de imagens para o setor fotovoltaico são aplicados especialmente para reconhecimento de defeitos e *hotspots* nos equipamentos, como visto em (Liu *et al.*, 2024) (Binti Ishak *et al.*, 2023) (Hu *et al.*, 2024). Os resultados obtidos são consideráveis promissores, porém ao utilizar esses processos para reconhecer falhas de forma genérica criam-se o problema de que a mesmo defeito pode ter diversos formatos e que se assemelham a outros, logo resultando em falsos positivos e falsos negativos. Outro problema visto é que ao detectar exclusivamente pontos quentes, o ambiente também pode prejudicar a leitura já que podem ocorrer de marcar acúmulos de calor em construções locais, o que afeta os modelos treinados. Nota-se que nestes trabalhos, são utilizados uma grande quantidade de imagens para os treinamentos, estes valores muitas vezes não são de fácil acesso e necessitam de uma grande capacidade computacional para serem processados, assim de forma a impossibilitar o treinamento da rede neural.

2.3.3 Filtro Gaussiano em Imagens

O filtro Gaussiano é amplamente usado no pré-processamento para o estudo e análise de imagens, com o intuito de suavização de bordas e redução de ruídos (Xu, Zhou and Fei, 2014). O filtro Gaussiano funciona como uma operação convolucional bidimensional, a qual aplica uma máscara de pesos da função Gaussiana que segue uma distribuição normal dos valores dos pixels. Isto significa que, tal como a aplicação do filtro Gaussiano para filtros de sinal, a qual utiliza um sinal suavizado para processá-lo, em imagens os valores das intensidades dos pixels são analisados e linearizados para manterem um valor aproximado, assim capaz de suprimir ruídos, (Xu, Zhou and Fei, 2014) .

Imagens de ambientes com forte interferência do cenário ao redor, em especial imagens térmicas de módulos fotovoltaicos, a aplicação do filtro Gaussiano se mostrou eficaz na remoção e redução dos efeitos dos ruídos nos objetos de estudo, como visto em (Guerriero and Daliotto, 2017). De acordo com (Hajjdiab *et al.*, 2023), a utilização deste filtro segue a conversão da imagem para cores cinzas para preservação de bordas e redução de ruídos, porém também podem ser usados em imagens coloridas como mostra (Chen, Li and Ling, 2020).

Logo, o filtro Gaussiano é uma técnica de suavização de contornos e remoção de ruídos nas imagens. A Equação 5 representa a função que caracteriza esse filtro, sendo os valores de x e y as coordenadas da máscara de suavização e σ o desvio padrão da distribuição:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5)$$

A aplicação desse filtro em imagens segmentadas contribui para a melhoria da qualidade da imagem, aumentando a acurácia das segmentações e diminuindo os ruídos (Chen *et al.*, 2023). Para a obtenção desses resultados para termografias de módulos fotovoltaicos, os valores da máscara operam com valores ímpares que alteram, comutam os valores dos *pixels* por valores de *pixels* ponderados locais, (Moradi Sizkouhi *et al.*, 2019). A eficiência deste método, com os valores ímpares mencionados, especialmente 3x3, 5x5 e 7x7 podem ser comprovados por (Pathak and Patil, 2023), o qual prova a redução de ruídos, manutenção das bordas e realce de regiões com *hotspot* e separação dos equipamentos em relação ao fundo da imagem.

2.3.4 Segmentação por Espaço de Cor

A segmentação por espaço de cor é consiste em separar partes de uma imagem com base nos seus valores e características das cores do cenário ou objetos a serem estudados, comumente usada no processamento de diversos tipos de imagens (Bhairnallykar and Narawade, 2023a). As imagens podem ser descritas como matrizes de números, sendo sua menor porção conhecida como *pixel*. Este elemento tem um valor respondente a imagem, por exemplo, uma imagem binária apenas tem dois estados (0 e 1) enquanto imagens cinzas possuem 1 *byte*, ou seja, 2^8 *bits* (0 a 255) e por último imagens coloridas compostas por 3 *bytes* que são os canais que possuem, tal como uma imagem RGB (*Red, Blue and Green*) ou HSV (*Hue, Saturation, Value*) (Serfa Juan and Kim, 2020) . Ao se limitar os valores desses canais, pode-se separar regiões com determinados valores de cor e de intensidade, assim serem transformados em valores binários do seguinte modo: os *pixels* dentro da faixa recebem o valor de 1, os que estão fora recebem o valor 0(Chen, Li and Ling, 2020)(Abhijith et al., 2020).

As variações de cores em uma termografia representam a temperatura a qual se encontram, cores mais azuladas estão relacionadas a zonas mais frias, quanto a alaranjadas são áreas quentes e a intensidade destes valores está associada a intensidade dessas duas cores. Analisar estas imagens e separá-las pela condição de intensidade da cor pode ser um desafio para uma segmentação com o espaço de cor RGB, visto que esse necessita controlar os 3 canais ao mesmo tempo para ajustar os valores até um filtro que satisfaça aquela intensidade. Dada essa situação, (Zhang *et al.*, 2022) utilizaram o espaço de cor HSV para a manipulação do filtro limiar (*thresholding*) que fosse capaz de separar as zonas de maior temperatura das termografias do restante, pois este formato de cor permite alterar a Saturação e o Brilho. Após este processo foi aplicado uma máscara binária, ou seja, se o *pixel* estava dentro da faixa recebia o estado de 1, caso contrário era atribuído o estado 0, assim segmentou-se a região de interesse.

2.3.5 Transformações Morfológicas

Transformações morfológicas são operações matemáticas baseadas na Teoria dos Conjuntos que aplicadas a imagens binárias para processar os objetos presentes na nelas baseadas em sua forma, (Hussain and Agarwal, 2016). Funcionam a partir de um elemento estrutural, também chamado de *kernel*, o qual percorrer a imagem e executa operações específicas sobre os *pixels*, modificando sua estrutura conforme sua configuração, capazes de adicionar ou remover determinados conjunto de *pixels*, (Pathak and Patil, 2023). Esse elemento estrutural é uma matriz composta por valores binários (0 e 1) que define os *pixels* ao redor do ponto de interesse a serem analisadas. As duas operações básicas são a erosão e a dilatação, as quais empregadas para modificar a morfologia dos objetos, no que compreende preencher lacunas, remover ruídos e suavizar contornos(Yu, Zhao and Wang, 2008; Hussain and Agarwal, 2016) .

A erosão diminui o tamanho das regiões dos objetos, atribuindo aos *pixels* o estado 0, caso haja um elemento com o mesmo valor na região que o *kernel* está a verificar . Assim, a erosão remove detalhes pequenos das bordas dos objetos ou elimina por completo pixels periféricos. A dilatação é o processo inverso da erosão, pois aumenta a espessura do objeto atribuindo o estado de 1 ao *pixel*, pois ao varrer a região, caso houver estados de 1 próximos, será adotado

este valor caso haja algum 0. Logo, a dilatação adiciona *pixels* às bordas, expande-as e une regiões dos objetos (Wang *et al.*, 2018).

A partir dessas duas operações, criam-se duas outras técnicas para melhorar a qualidade de imagens segmentadas, chamadas de abertura e fechamento binário. A abertura é a erosão seguida de uma dilatação, com o intuito de eliminar ruídos e pequenos conjuntos de *pixels* isolados, o quais não correspondem ao objeto analisado. O fechamento binário consiste na dilatação seguida de uma erosão, assim de forma a preencher zonas que perderam alguns pixels em segmentações anteriores e ainda preserva contornos. Estas operações são essenciais para o pós-processamento de imagens binárias segmentadas, pois restauram formas perdidas e eliminam ruídos,(Zhang, 2009) .

O processamento de termografias de módulos fotovoltaicos beneficia-se destas operações, pois devido a natureza do ambiente que se encontram, as imagens estão sobre influência de ruídos e interferências do cenário ao redor que podem prejudicar a qualidade da imagem. A escolha do *kernel* deve ser ponderada em relação a visualização da imagem, pois este afetará o tamanho dos objetos que se deseja preservar ou remover. Em (Pathak and Patil, 2023), foi aplicado um *kernel* com tamanho 9×9 para melhor desempenho durante a abertura morfológica e notou-se uma melhora em seu formato.

3 Metodologia

3.1 Procedimentos do Trabalho

A finalidade deste trabalho é localizar avarias em cima dos módulos fotovoltaicos por meio de imagens térmicas registradas. Para tal, deverão ser aplicadas técnicas de processamento e segmentação de imagem para demarcá-las. Logo, para que o trabalho siga uma linha de raciocínio técnico-científico próprio e os resultados sejam os mais próximos de um ambiente real, foi necessário usar equipamentos em funcionamento, anotar suas características, capturar seus perfis térmicos, e processar as imagens obtidas. Portanto, os procedimentos foram divididos em 3 partes fundamentais, que se subdividem, assim de forma a descrever cada etapa realizada e prevenir que erros possam influenciar os resultados obtidos.

A primeira parte é a montagem do *setup* de teste e coleta de imagens térmicas, com a finalidade de utilizar um ambiente com equipamentos em condições de uso real, e ainda, emular avarias nos módulos fotovoltaicos. A montagem do *setup* utilizou-se de equipamentos que apresentem um certo uso, ou seja, equipamentos que fizeram parte de uma instalação fotovoltaica, porém não estão em uso. A captura das termografias será feita através de uma câmera térmica operado por uma pessoa manualmente, a fim de emular um técnico que venha usar estas técnicas em suas instalações residenciais.

A segunda parte trata-se de configuração, ajuste e organização das imagens para a montagem do *dataset* das termografias com o propósito de treinar uma rede neural, capaz de reconhecer os módulos nas imagens térmicas. A montagem *dataset* é importante, pois mostra como está o perfil térmico dos painéis nas termografias, que pode ser afetado por eventos de difusão térmica e óptica, sendo assim, uma variedade de imagens dos mesmos equipamentos demonstram se há outros pontos de calor que não foram observados em outras amostras. A partir deste *dataset*, o modelo Yolov8 de rede neural é treinado para que os painéis fotovoltaicos

sejam identificados e segmentados das termografias, assim evitando que outros pontos quentes fora dos equipamentos sejam processados e identificados, logo prejudicando a localização de avarias em cima dos módulos.

A terceira parte consta os processamentos e segmentação dos pontos quentes das imagens, assim possibilitando demarcar os locais com maior temperatura que representam as avarias nos módulos. Com as identificações dos módulos da etapa anterior, os próximos passos são de tratamento das imagens com os módulos segmentados, a fim de eliminação de ruídos, suavização de bordas e avaliar como que está a questão da variação de intensidade de cor, o equivalente as temperaturas registradas. Caso haja alguma inconformidade na relação do perfil de cores, aplicou-se técnicas de *thresholding* de espaço de cor, processamentos morfológicos e a demarcação do ponto, para que, seja comparado com a imagem original e verificado posteriormente.

Portanto, de forma a resumir, os procedimentos realizados neste trabalho abrangem: (i) a montagem de um *setup* de testes que simule módulos fotovoltaicos avariados; (ii) a coleta das imagens térmicas dos equipamentos; (iii) o treinamento da rede neural Yolov8 que identifique os painéis nas termografias; (iv) a aplicação dos processos de segmentação e de processamento de imagens para demarcar os *hotspots* ; (v) localizar as avarias. Essas etapas foram capazes de localizar e segmentar os pontos de calor no equipamento avariado com boa precisão. A Figura 3 mostra de forma esquemática, como foram feitas as divisões das etapas e subdivisões.




Figura 3 Etapas da metodologia do Trabalho.

3.2 Setup de Testes

A montagem de um setup de teste foi feita para que todo processo de aplicação de algoritmos de identificação, processamento e segmentação de imagens fossem feitos com equipamentos reais e validados, assim provando a eficácia do método. Portanto, com a montagem do setup

próprio, era possível emular avarias e verificar se havia outros elementos que estavam a afetar os painéis fotovoltaicos.

Para o setup foram utilizados três módulos fotovoltaicos mono-cristalinos de modelo SE-R27KMC-38, com capacidade de tensão de circuito aberto de $39V_{dc}$. Estes equipamentos foram usados em uma instalação fotovoltaica anteriormente, porém substituídos devido a modernização do sistema, sendo assim, apresentam condições excelentes para os testes. A Figura 4 mostra que os valores de tensão de circuito aberto, perto da faixa de $39V_{dc}$, estes valores menores ao esperado poderiam estar relacionados a poeira e sujeira sob o equipamento, desta forma, é de se esperar que sejam demarcados pelo algoritmo. Durante o teste, ou seja, na captura das termografias, item 3.3, foram feitas 5 verificações das tensões geradas pelos módulos.



Figura 4 Valores das medições de Tensão de circuito aberto de cada equipamento. Os valores da esquerda para direita são 35.03, 34.95, 33.6 Vdc.

A emulação de uma avaria nos módulos fotovoltaicos foi feita com a aplicação de camadas de fitas isolantes em cima das células dos módulos fotovoltaicos. A proposição desta tarefa tem como objetivo emular avarias de intensidade severa, assim vão ter destaque nas termografias e pretende-se que sejam observadas de qualquer ângulo durante o registro térmico. A Figura 5 mostra que foram feitos 4 pontos com as fitas isolantes.




Figura 5 Camadas de fita isolante colocadas sobre os módulos fotovoltaicos para emular avarias.

A configuração da montagem do setup pode ser vista no desenho da Figura 6. Os módulos fotovoltaicos estavam ligados em série, para que suas tensões fossem somadas e monitoradas por um multímetro. Os equipamentos foram apoiados em uma parte estrutural do local e ofereceu uma inclinação de $31,5^\circ$ para o Noroeste, praticamente rente a Sol no momento do teste. O experimento ocorreu na cidade de São Paulo, estado de São Paulo, Brasil, no dia 16 de abril de 2025, em uma temperatura ambiente de 20°C e céu parcialmente nublado.




Figura 6 Esquemático do Setup de Teste. Os retângulos em preto representam as camadas de fita isolantes e sua disposição em cima de cada painel.



Figura 7 Fotografia da disposição dos módulos fotovoltaicos no local da realização do trabalho.

3.3 Registro Termográfico e Coleta de Imagens

Os registros das termografias foram feitos na configuração dos módulos fotovoltaicos descrito no item anterior, a finalidade desta tarefa está relacionada a coleta de diversas imagens dos equipamentos de forma há capturar os perfis térmicos totais dos equipamentos. O registro termográfico pode sofrer problemas devido a angulação que se está a capturar a imagem, distância de captura e reflexão de luz contra a câmera, logo, ao realizar diversas termografias, pretende-se verificar todos os pontos de calor nos painéis. A captura seguiu de forma a que em cada imagem apresenta-se pelo menos um módulo fotovoltaico, que ainda, fosse capaz de verificar que havia um ponto quente nele, como exemplifica a Figura 8. As distâncias e

angulações variaram durante o processo, porém ainda seguindo os critérios anteriormente descritos.




Figura 8 Amostra da termografia registrada dos módulos.

O equipamento que foi utilizado para esta etapa foi a câmera Fluke TiS10, um equipamento de uso relativo simples que pode ser operado tanto por um técnico quanto por uma pessoa instruída, sendo assim, há a possibilidade de utilizar esta técnica e outras instalações fotovoltaicas menores. A Figura 9 mostra uma coletânea de imagens registradas, como seriam utilizadas para realizar o treinamento da rede neural, optou-se por remover as informações no display de algumas imagens, enquanto outras permaneceram com elas.




Figura 9 Coletânea de imagens registradas.

3.4 Criação e Preparação do *Dataset*

As imagens termográficas coletadas têm como finalidade mostrar o perfil térmico dos equipamentos em diversos ângulos e distâncias, o que possibilita registrar quais são todos os pontos quentes, estes representam locais com possíveis avarias nos equipamentos. Portanto, o registro capturou as camadas de fitas que foram propositalmente colocados em cima dos módulos, e outros elementos, como sombreamentos das estruturas locais e sujeira acumulada. Logo, ampliando o aspecto de informações sobre outros elementos que estavam prejudicando os painéis fotovoltaicos.

A partir destas imagens, foi montado o *dataset* que será utilizado para o treinamento da rede neural. Foram capturadas 300 termografias dos equipamentos, todas elas mostrando pelo menos um módulo com algum ponto quente sob. O tamanho padrão de cada imagem térmica era de 240 x 320 pixels no formato <x.jpg>, características padrão da câmera utilizada. Para garantir que as dimensões das imagens de entrada coincidam com as de saída da rede após o treinamento, foi necessário realizar o redimensionamento das termografias para o tamanho de 482 x 636 pixels, para tal, foi utilizado o *software* Irfanview. Este processo é importante, pois quando as imagens processadas e os locais demarcados com os pontos quentes vierem a ser comparados com as imagens originais, a demarcação dos *hotspots* estejam alinhadas com as regiões de maior temperatura registrada, assim a aumentar à acurácia da demarcação, identificação e localização da anomalia térmica nos equipamentos.

Após a etapa de preparo, as imagens foram divididas em 2 grupos principais, o primeiro com 290 unidades foi utilizado para a rede neural, os segundo com as demais 10 foram reservadas para testar o desempenho e acurácia da rede. A divisão das imagens do primeiro grupo seguiu nas proporções de 232 (80%) para treinamento e 58 (20%) para validação, estas proporções seguem os padrões de treinamento de redes neurais convolucionais. O segundo grupo será utilizado para a verificação da acurácia do sistema, assim de forma a garantir que a rede neural está a reconhecer apenas módulos fotovoltaicos em termografias, e nenhum outro elemento.

A seleção dos grupos de imagens permite que sejam feitas as anotações para o auxílio do treinamento da rede. As marcações são feitas para que a rede neural receba exemplos visuais rotulados especificamente para os objetos que deseja reconhecer e segmentar. Portanto, foi utilizado a ferramenta *online* MakeSense, a qual possibilita realizar o *upload* das imagens capturadas e fazer marcações nos objetos. As anotações foram feitas manualmente nos módulos fotovoltaicos das 290 termografias, assim de forma a gerar um arquivo <x.coco> que corresponde a demarcação da localização dos painéis nas imagens. Ao utilizar este arquivo junto as imagens, a rede neural será capaz de identificar com maior acurácia os equipamentos, assim segmentando-os do restante do fundo, o que permitirá apenas analisar os pontos quentes neles. As marcações seguiram o seguinte parâmetro, para ser marcado como um módulo fotovoltaico é necessário que as aristas de cima e de baixo estavam nítidas na imagem, e que pelo menos uma arista lateral estivesse evidente, assim pedaços desconexos dos equipamentos não seriam detectados e segmentados, o que permitiria melhor a acurácia das marcações e por consequência da rede neural. A Figura 10 mostra o processo de marcação manual dos painéis nas imagens termográficas capturadas, na figura como ambos os equipamentos apresentavam as aristas de cima, de baixo e a lateral, foram marcados como módulos fotovoltaicos.




Figura 10 Marcações das posições para identificar os módulos fotovoltaicos nas imagens no MakeSense.

3.5 Treinamento da Rede Neural

A rede neural tem como finalidade detectar e segmentar os módulos fotovoltaicos nas termografias, a fim de que apenas os pontos quentes em cima dos equipamentos sejam processados e analisados posteriormente nas próximas etapas. O treinamento da rede neural foi feito dentro do ambiente *online* do Google Colab, que permite ter acesso a *hardwares* mais avançados por um valor monetário acessível, logo a diminuir o tempo de processamento que a rede neural precisaria para analisar todas as imagens e anotações disponibilizadas pelo *dataset*. Desta forma, a configuração dentro do Google Colab pode ser analisada na Tabela 1.

Tabela 1 Parâmetros usados no ambiente do Google Colab.

Parâmetro	Versão
Python	3
GPUs	GPU A100
Aceleração de Hardware	Habilitado

Após a configuração do ambiente, o *dataset* com as imagens e anotações foi carregado na plataforma via Google Drive, o que possibilitou dar início a configuração da rede neural. O modelo de rede neural utilizada foi o Yolov8, na versão YOLOv8x-seg, a qual é capaz de realizar detecções com *bounding-box* (i.e., retângulos com os valores de certeza de detecção) e segmentação instantânea (i.e., a camada que marca o formato e as bordas do objeto de interesse). A escolha específica deste modelo deu-se devido à natureza das imagens que estão sendo trabalhadas, como era necessário excluir todo e qualquer elemento que não representava uma leitura térmica no equipamento, apenas a detecção com uma *bounding-box* não seria precisa o suficiente para somente segmentar a área do equipamento, com o risco de outros elementos serem segmentados. Portanto, utilizar-se de uma versão com segmentação instantânea beneficiava a leitura com a área precisa do equipamento, assim de forma a prevenir eventuais processamentos de temperaturas fora da superfície dos painéis. Os parâmetros do treinamento estão mostrados na Tabela 2, a rede utiliza 100 *Ephocs* (i.e., verificará 100 vezes as imagens e informações do *dataset*) em *Batches* de 8 (i.e., em grupos de 8) com o tamanho máximo da imagem de 768x768 pixels.

Tabela 2 Parâmetros de treinamento do Yolov8.

Parâmetro	Valor
<i>Epochs</i>	100
<i>Batch</i>	8
Tamanho da imagem de entrada	768×768

Após o treinamento da rede neural, os módulos fotovoltaicos são detectados e reconhecidos nas termografias, o que possibilita aplicar uma máscara de cor branca ao redor dos equipamentos. A finalidade desta aplicação, permitirá que apenas os valores das cores do equipamento sejam avaliados, ou seja, como a intensidade da cor na termografia está associada a temperatura, avaliar a intensidade das cores significará avaliar temperatura no equipamento. Portanto, ao analisar os pontos de maior intensidade de cor , e segmentá-los do restante da imagem, será assim capaz de fornecer a localização dos *hotspots* em cima dos equipamentos, logo as avarias. A Figura 11 mostra o processo de aplicação da máscara branca em cima dos painéis.




Figura 11 Processo de Reconhecimento, Detecção e Aplicação da Máscara de cor Branca.

3.6 Filtro Gaussiano, Segmentação por *Thresholding* de Espaço de Cor e Processamento Morfológico

Os processos descritos nesta etapa têm como finalidade de analisar e segmentar as regiões com maior intensidade de cor, as quais correspondem os pontos com *hotspots*, assim estes representando as avarias nos módulos. Portanto, ao analisar os valores das intensidades de cores das imagens, processá-los a fim de montar seus aspectos geométricos nas imagens térmicas com os módulos detectados e com a máscara branca da etapa anterior, será fundamental para que se possa demarcar e localizar as avarias nos próximos itens. Sendo assim, ao aplicar as técnicas descritas neste segmento, pretende-se separar os pontos quentes das termografias.

Os processos descritos neste item e no próximo, 3.6 e 3.7, foram realizados nos ambientes de desenvolvimento *VSCode*, uma vez que não é necessário um esforço computacional equivalente ao treinamento da rede neural, assim de forma a reduzir o custo monetário envolvido com este trabalho e também facilitar a utilização de outros *hardwares* com menor capacidade de processamento de informações.

3.6.1 Filtro Gaussiano

O primeiro processo a ser feito é a aplicação do filtro Gaussiano, que tem por objetivo reduzir ruídos e imperfeições nas imagens termográficas. Durante o processo de captura das imagens termográficas, item 3.3, possuem ruídos originados ao manuseio do equipamento, ângulo de inclinação, qualidade do equipamento, ou também informações da câmera que podem afetar a análise e gerar erros. Para suavizar estes defeitos, é necessário aplicar o filtro Gaussiano que

preservará as bordas das regiões térmicas de maior intensidade e sem que prejudique a leitura, como pode ser visto na Figura 12 .




Figura 12 Aplicação do Filtro Gaussiano em imagens térmicas dos módulos fotovoltaicos.

Para otimizar a aplicação do filtro, foram testadas algumas combinações de valores dos elementos para a filtragem dos ruídos nas imagens, como podem ser visualizados na Tabela 3 . A utilização de parâmetros diferentes serve para verificar quais são os valores ideais do filtro que podem ser aplicados, sem que prejudiquem a leitura, processamento e interpretação da imagem.

Tabela 3 Valores dos Elementos para cada aplicação do Filtro Gaussiano.

Parâmetros		
X	y	σ
3	3	10
3	3	100
5	5	10
5	5	100
7	7	10
7	7	100

3.6.2 Segmentação por *Threshold* de Espaço de Cor

A segmentação por *threshold* de espaço de cor separa regiões dos objetos por características atribuídas a cor, como por exemplo regiões com tons ou intensidade diferentes, assim de forma

a analisá-las de forma independente e buscar características atribuídas a elas. Desta forma, ao verificar os valores de intensidade das cores, os quais correspondem a temperatura dos módulos fotovoltaicos, é possível segmentar as regiões com *hotspots* do restante da imagem.

A imagem com o filtro Gaussiano já aplicado é dividida no espaço de cor *HSV* e calcula-se os histogramas para cada canal, para obter-se os valores da matriz de cores (*Hue*), saturação (*Saturation*) e brilho (*Value*), como mostra a Figura 13. Esta operação foi feita em uma imagem no formato *RGB*, com intuito de analisar fundamentalmente os canais de saturação e brilho para traçar o valor do *Threshold* nestes parâmetros. Os valores dos histogramas apresentam grandes picos nos extremos, o que corresponde a máscara branca aplicada no item 3.5, logo deverá ser eliminada.




Figura 13 Valores dos Espaços de cor dos painéis em HSV.

Os valores dos histogramas apresentam grandes picos nos extremos, o que corresponde a máscara branca aplicada no item 3.5, logo deverá ser eliminada. Baseado nos valores de histogramas de saturação das imagens, nota-se picos dentre os valores de 75-96 até 220-230, sendo assim o limiar deverá ser ajustado para este valor, como pode ser visto na Figura 14.

Ao ajustar os valores do *threshold*, é aplicado uma máscara binária na imagem, os estados que estão dentro do limiar são atribuídos os valores de 1, enquanto aos que estão fora recebem o

estado de 0. A substituição dos estados por 0 ou 1 permite que sejam visualizados apenas os elementos de interesse, ou seja, os pontos de maior temperatura nos módulos fotovoltaicos, assim a separar as regiões com *hotspots*, onde estão as avarias, das demais regiões que não apresentam problemas. A Figura 15 mostra o processo aplica a uma termografia com base nos valores dos histogramas de saturação.




Figura 14 Ajuste de *threshold* baseado nos valores do histograma de saturação.




Figura 15 Máscara binária aplicada à imagem após o *threshold*.

Transformações Morfológicas

As imagens segmentadas e transformadas em valores binários passaram por transformações morfológicas (abertura e fechamento) que consistem em operações quanto a morfologia das regiões de interesse, ou seja, consiste em modificar parte do formato destes elementos. A finalidade destas operações é a de corrigir ruídos e melhorar aspectos das segmentações, como por exemplo remover pequenas zonas de pixels que não correspondem a informações relevantes a imagem que foram segmentados, ou também corrigir pixels que foram retirados da imagem durante o *Threshold*. Para os processos a seguir, foram escolhidos 3 tamanhos de *kernels*, conforme a Tabela 4, o propósito de testar diferentes tamanhos consiste em utilizar 3 tipos de ajustes, um suave (3x3), um médio (5x5) e um forte (7x7), assim será possível verificar qual é o *kernel* mais apropriado para corrigir as imperfeições.

Tabela 4 Valores do Kernel utilizados para ambas transformadas morfológicas.

Valores do Kernel
3x3
5x5
7x7

A abertura binária auxilia na limpeza de pequenas regiões de *pixels* que foram segmentadas e que não correspondem necessariamente aos *hotspots*. Portanto, ao aplicar este processo nas imagens binárias com as avarias, ocorre a limpeza desses pequenos ruídos que podem marcar regiões que não mostram se há uma avaria no local. A Figura 16 mostra a aplicação da abertura binária em regiões segmentadas dos módulos fotovoltaicos.




Figura 16 Abertura binária: antes e depois da aplicação.

O fechamento binário das regiões segmentadas, dos *hotspots*, restaura *pixels* que foram segmentados na etapa anterior, item 3.6.2, o que podem prejudicar a leitura da região de interesse, pois criam-se pequenas falhas que indicam que não há um ponto quente no local. Sendo assim, ao aplicar este processo, deseja obter a restauração de pontos perdidos durante a segmentação e entender melhor a geometria da avaria. A Figura 17 mostra a aplicação do processo e como a restauração de alguns pixels na área em questão.




Figura 17 Fechamento binário: antes e depois da aplicação.

3.7 Demarcação e Localização

Os *hotspots* segmentados passam por um processo no qual são transformados em camadas, que sobrepostas a imagem original, possibilitam para a visualização em relação a posição onde se encontra a avaria. As camadas permitem verificar a segmentação dos pontos de interesse sob os módulos e destacá-los individualmente para identificar cada avaria no sistema através de

demarcações das coordenadas destas na imagem, assim pode-se notá-los e verificar onde estão as avarias na instalação fotovoltaica e conhecer sua origem. A Figura 18 fornece um exemplo das regiões segmentadas que se tornaram camadas, portanto, foram aplicados os processos anteriores para que se divida a área total dos módulos fotovoltaicos do restante da imagem e que se segmentou o equivalente a área binária dos equipamentos, transformando-os em camadas individuais para a visualização em relação ao total.




Figura 18 Exemplo de áreas dos módulos segmentadas sobrepostas à imagem original.

As regiões segmentadas são então marcadas e suas coordenadas registradas, o perímetro ao redor da região segmentada é demarcado com uma linha preta sobre a imagem original para fins de contraste. A demarcação localiza os *pixels* dos pontos de maior temperatura e os registram na imagem, como visto na Figura 19. Portanto, com as áreas registradas, é feita a demarcação das coordenadas na imagem original, para assim localizar as avarias nos módulos. Portanto, ao analisar as demarcações nas termografias é possível localizar as avarias nos equipamentos do setup de teste.




Figura 19 Demarcação dos com pixels maior intensidade de cor, representando os pontos de calor.

4 Resultados e Discussões

4.1 Coleta de Informações e Termografias do setup de teste

O *setup* de teste proporcionou um ambiente que possibilitou a captura de diversas termografias que mostraram o perfil térmico dos módulos fotovoltaicos em ângulos e posições diferentes, como também avaliar a queda de tensão gerada pelos painéis. Mesmo com uma instalação fotovoltaica relativamente pequena, composta de três módulos, os efeitos das avarias em cima os equipamentos foram perceptíveis, de forma a possibilitar a criação de um conjunto das imagens térmicas para o treinamento da rede neural e da aplicação dos processos para localização das avarias.

Durante os registros das termografias, as verificações das tensões geradas foram feitas cinco vezes. A primeira vez sem as camadas de fitas isolantes, as restantes foram feitas durante início até o término da captura de imagens. A Figura 20 é o gráfico dos valores registrados neste período, que consta por volta de 45 minutos, uma queda de tensão de 9,2 V_{dc} na produção de energia elétrica. Portanto, ao aplicar as fitas isolantes aos módulos observou-se a queda da produção energética.




Figura 20 Valores da queda de tensão gerada pelos módulos durante os captura de imagens térmicas.

As fitas isolantes sob os módulos fotovoltaicos emularam eficazmente avarias em cima dos equipamentos, as temperaturas registradas sobre estes elementos foram consideravelmente maiores em relação ao restante dos equipamentos. A Figura 21 mostra as termografias dos locais com fitas isolantes, assim a marcar pontos quentes em cima dos painéis, ou seja, a energia ao invés de ser produzir corrente elétrica, está a dissipá-la em forma de calor localizado. Logo, as fitas isolantes conseguiram produzir um *hotspot*, ou seja, emular uma avaria em um módulo fotovoltaico.




Figura 21 Verificação da temperatura das fitas isolantes em relação ao restante dos módulos.

4.2 Resultados dos Treinamento da Rede Neural e Detecção dos Módulos nas Termografias

A evolução das métricas de qualidade do treinamento são apresentadas na Figura 22, de forma a medir o desempenho do modelo treinado para a detecção (*bounding boxes*) representadas pela letra B, e para a segmentação instantânea (*instance segmentation*) marcado com a letra M. O comportamento dos gráficos está com o esperado para um treinamento considerável bom, pois ao decorrer das *epochs*, os valores estão a tender a 1, e não há picos significativos de queda dos parâmetros com retornos espontâneos, o que significaria que poderia haver a presença de *overfitting*, mas pela figura isto não ocorre.




Figura 22 Gráficos da evolução das métricas durante o treinamento.

Os valores finais das métricas *Precision*, *Recall*, *mAP*, *mAP50-95* para ambas os processos detecção (*bounding boxes*) e segmentação instantânea (*instance segmentation*), são indicados na Tabela 5. Os resultados indicam que o modelo obteve um bom desempenho, pois todos estavam acima de 0,95, alguns tendendo a chegar a 1.0 , o que evidencia uma boa generalização. Portanto, pelos aspectos do gráfico que permaneceram tendendo ao 1.0 sem que alterações evidentes e os valores das métricas estarem acima de 0.90, não há sinais de *overfitting* do modelo, sendo assim a rede neural conseguiu aprender a reconhecer os módulos corretamente.



















Tabela 5 Valores das métricas de qualidade obtidos ao final do treinamento.

	<i>Precision</i>	<i>Recall</i>	mAP	mAP50-95
<i>Bounding-Boxes</i> (B)	0.95991	0.99	0.9919	0.97217
Segmentação (M)	0.95991	0.99	0.9919	0.96323

Os resultados visuais do treinamento da rede neural, logo a detecção (*bounding boxes*) e segmentação instantânea (*instance segmentation*) foram testados com as imagens que não

estavam presentes no *dataset*. Os valores da acurácia das detecções e forma de 0.94, ou seja, 94% de certeza nos reconhecimentos dos módulos fotovoltaicos nas termografias, o que resulta em uma garantia que as análises das próximas etapas foram exclusivas em painéis fotovoltaicos, evitando quaisquer erros com pontos quentes que não parte dos equipamentos. Os resultados dos treinamentos da rede neural são apresentados na Tabela 6.

Tabela 6 Imagens dos módulos detectados para o teste - 100 epochs

Imagem	Nº de módulos na imagem	Nº de módulos detectados	Deteção	Confianças das detecções	Segmentação
	3	3		0.96 0.91 0.90	
	2	2		0.95 0.90	
	3	3		0.95 0.95 0.87	
	3	3		0.96 0.96 0.91	
	2	2		0.97 0.95	
	3	3		0.96 0.95 0.94	
	3	3		0.95 0.94 0.94	
	3	3		0.97 0.95 0.87	
	3	3		0.96 0.95 0.94	
	2	2		0.96 0.96	

4.3 Efeitos do Filtro Gaussiano

A aplicação de diferentes valores do filtro Gaussiano, teve como finalidade a diminuição de ruídos e preservação das bordas das regiões térmicas nas imagens, de forma a melhorar aspectos gerais da imagem, e como também, auxiliar durante a segmentação por *threshold* de espaço de cor. A aplicação do filtro, de maneira geral possibilitou que informações da câmera térmica, que estavam sob algumas imagens dos módulos, fossem borradas e preservando apenas a superfície do equipamento, como também, outros tipos de imperfeições fossem suavizados, estas atribuídas a movimentação da câmera, reflexo de luz sobre o equipamento e interferências do ambiente

Ao aplicar o filtro Gaussiano com os parâmetros da Tabela 3, pode-se observar que houve suavização de ruídos sobre a imagem, de forma que a intensidade dos valores afetou a redução proporcionalmente. Dentre todos os valores, o filtro $x = 5$, $y = 5$, $\sigma = 10$, foi que apresentou o melhor desempenho em borrar as informações, preservar as bordas de regiões de áreas de diferentes temperaturas, e ainda possibilitou a visualização dos contornos dos painéis fotovoltaicos após a segmentação por espaço de cor e aplicação da máscara binária, Figura 23.



Figura 23 Segmentação por *Threshold* de espaço de cor HSV sem e com o filtro gaussiano $x = 5$, $y = 5$, $\sigma = 10$.

A Figura 24 mostra a aplicação de todos os parâmetros em uma imagem, o valor do filtro anteriormente citado foi o que apresentou o melhor equilíbrio entre os valores se que prejudicasse a leitura da imagem de modo geral.




Figura 24 Aplicação do Filtro Gaussiano de acordo com a Tabela 3.

4.4 Valores do Threshold de Espaço de Cor – HSV

A segmentação por *threshold* de espaço de cor mostrou ser fundamental para que separar os pontos quentes das imagens, assim a possibilitar verificar de forma nítida a localização das avarias demarcadas nas imagens. Ao segmentar os painéis nas termografias, baseados nos valores dos histogramas de cor do espaço HSV, foi possível separar os elementos com maior intensidade de mesma cor do restante da imagem, essa relação de cor e intensidade, a qual está associada a temperatura, permitiu extrair os pontos quentes das imagens de forma que ficassem claros qual era o local onde estavam.

A utilização dos histogramas para analisar o perfil de cores da imagem no espaço HSV foi capaz de separar a matriz de cores, saturação e brilho de cada uma delas. Como na maioria das imagens, não há uma variação da coloração muito significativa, já que grande maioria delas têm um tom alaranjado, logo não houve grandes mudanças com a matriz de cores (Hue) e ao avaliar os grandes picos de quantidade de pixels nas bordas dos gráficos de brilho (Value) e saturação (Saturation) estes estavam relacionados a máscara branca da imagem, Figura 25.




Figura 25 Variação dos histogramas da imagem.

Ao extrair os valores periféricos dos dois espaços, assim a eliminar os valores da máscara branca do histograma, nota-se que há picos dos valores, correspondentes a regiões com cores de maior intensidade, especialmente na saturação, Figura 26. Logo, ao segmentar a imagem com base nestes picos, foi possível extrair os *hotspots* das imagens a partir destes valores.




Figura 26 Histograma com os picos da saturação.

A fim de confirmar que os valores obtidos anteriormente, eram parte do *hotspot*, os mesmos foram analisados com uma imagem do ponto quente somente, que confirmou a existência de picos da saturação na imagem relacionados aos pontos quentes, Figura 27.




Figura 27 Histograma da Saturação no *hotspot*.

Portanto, ao analisar as imagens de teste quanto aos valores dos histogramas para identificar o valor para *Threshold* de espaço de cor, chegou-se aos valores da Tabela 7, nesta faixa é possível segmentar os pontos quentes das imagens com esta técnica.

Tabela 7 Valores do filtro do espaço de cor HSV

Hmin	Smin	Vmin	Hmax	Smax	Vmax
0	75	0	179	220	255

4.5 Melhorias com as Transformações Morfológicas

As duas transformações morfológicas aplicadas aos pontos quentes das termografias, mostraram-se eficientes para aperfeiçoar a segmentação, o contorno e formato das regiões segmentadas, assim de forma a facilitar as demarcações das avarias em cima dos painéis. Os objetivos principais ao utilizar estas técnicas eram a redução dos ruídos pela abertura binária, conjuntos pequenos de pixels que não representavam os *hotspots* dos módulos, e a restauração de pixels segmentados por fechamento binário, partes das regiões de interesse que foram perdidas e que compunham a avaria.

Durante o trabalho, aplicou-se três tamanhos diferentes de *kernel*, de acordo com a Tabela 4, para determinar qual valor seria o mais adequado se utilizar para a abertura binária e fechamento binário, de maneira que seja o mesmo para ambas as operações. Os testes mostraram que o *kernel* que obteve o melhor desempenho foi o de 5x5. A escolha do *kernel* 5x5 é um equilíbrio entre suavização e preservação de detalhes importantes, neste procedimento um kernel muito pequeno (3x3 ou menor) foi insuficiente para remover ruídos relevantes, enquanto um kernel muito grande (7x7 ou maior) degradou ou distorcer as formas reais dos *hotspots*. O *kernel* 5x5 permitiu, assim, realizar uma limpeza eficaz da segmentação e garantir que as avarias reais fossem demarcadas com contornos consistentes.

Os efeitos do fechamento binário são observados em diversas segmentações nas quais lacunas e imperfeições de pixels em pontos quentes foram restauradas, logo aprimorando o formato da área segmentada, Figura 28. Portanto, ao aplicar esta técnica aos processamentos das imagens é notório que se terá ganhos nos formatos das segmentações.




Figura 28 Melhoria dos aspectos das regiões segmentadas com o fechamento binário.

A abertura binária não só reduziu de forma evidente os conjuntos de pixels menores, como também removeu as bordas dos equipamentos segmentados no item 3.6.2, que já estavam claras nos processos anteriores, logo a beneficiar a visualização dos pontos quentes nas imagens, Figura 29.




Figura 29 Diminuição de regiões com poucos pixels e eliminação da borda do painel após a abertura binária.

Portanto, ao aplicar estas técnicas aos processamentos das imagens, notou-se ganhos relacionados aos aspectos morfológicos delas, no quesito de remover e restaurar conjunto de pixels nas imagens. Estes ganhos as imagens são importantes para marcar o formato e localização das avarias em cima dos módulos fotovoltaicos.

4.6 Demarcação das Avarias em relação as Imagens Originais

As transformações morfológicas mostraram-se capazes de melhor o formato dos pontos quentes deixando-os claros e evidentes nas imagens. A partir destas segmentações, todos os elementos foram transformados em camadas diferentes e atribuídos uma cor a eles, para que fossem visualizados individualmente. O fechamento binário, além de modificar a geometria dos elementos, também foi capaz de manter com clareza o contorno dos módulos, o que beneficiou quando foram feitas as sobreposições dos elementos segmentados com a imagem original. Os contornos demarcados possibilitaram ver com clareza havia apenas os pontos quentes dos módulos, nem outro elemento externo foi registrado. As bordas e avarias junto a sobreposição da imagem original são ilustradas na Figura 30.




Figura 30 As camadas registradas colocadas sobre a imagem original.

Com a sobreposição dos elementos na imagem original, não era mais necessário manter-se as bordas já que não compunham como avarias nos módulos. Logo, a abertura binária foi capaz de removê-las sem que prejudicassem as avarias, mantendo assim apenas os pontos de interesse sob a imagem original. Qualquer suspeita de falsos positivos ou elementos externos foram totalmente saciadas, pois as demarcações mostraram eficazes para analisar se aquelas camadas eram as avarias em cima dos módulos. Como o resultado da remoção das bordas as posições dos pontos quentes ficaram claras na imagem, como ilustra a Figura 31.




Figura 31 Avarias sobrepostas à imagem original.

Cada camada, conjunto de *pixels*, possui uma posição dentro da imagem, com esta informação foi possível demarcar e extrair as coordenadas x e y dos destes. Logo, ao redor de cada ponto, foi possível fazer contornos de cor preta, para destacar do fundo, as avarias localizadas. Os contornos e a localização das avarias em cima dos módulos fotovoltaicos podem ser vistos na Figura 32.




Figura 32 Localização das avarias nos módulos.

4.7 Avarias Localizadas em cima dos Módulos Fotovoltaicos

Os objetos de estudo deste trabalho são três módulos fotovoltaicos, ligados em série, que operaram durante a captura de imagens termográficas, com fitas isolantes que emulavam avarias. A finalidade do trabalho é aplicar técnicas de segmentação e processamento de imagens para localizar avarias em cima dos painéis por meio de termografias, de forma a detectar quais são os elementos que prejudicam a produção de energia, e que causam *hotspots* em cima dos equipamentos. A montagem do setup, captura de termografias, treinamento da rede neural e os processamentos restantes foram capazes de marcar pontos quentes nas termografias dos painéis. Portanto, ao comparar as demarcações feitas pela metodologia, é necessário que a localização de alguns contornos seja semelhante a posição das fitas isolantes, colocadas sob os equipamentos, itens 3.2 e 4.1, como também que os outros pontos registrados tenham algum elemento que esteja a afetar o módulo.

Ao observar as marcações sobre os módulos e as termografias registradas, primeiramente nota-se que os processos aplicados foram capazes de demarcar a posição das fitas isolantes nos equipamentos, sendo estas as avarias mais notórias e com maior potencial de prejudicar os painéis, visto que são obstruções físicas ativas com difícil remoção. Além das fitas isolantes, haviam outras marcações nas termografias, que indicavam elementos diferentes que estavam a causar algum acúmulo de calor, de menor intensidade comparado com os registrados em relação as películas. Ao investigar as causas destes pontos de calor, na posição demarcada pelos processos, estavam a apontar para regiões com acúmulo de poeira e sujeira como também sombreamentos oriundos das estruturas locais. As Figura 33, Figura 34, Figura 35 mostram as marcações feitas nas termografias que mostraram a existência de elementos que prejudicavam os módulos fotovoltaicos, sendo as películas, sujeira e sombreamento.




Figura 33 Análise das avarias no painel fotovoltaico da direita.




Figura 34 Análise das avarias no painel fotovoltaico do meio.




Figura 35 Análise das avarias no painel fotovoltaico da esquerda.

As localizações registradas nas etapas anteriores possibilitaram verificar, nos módulos fotovoltaicos, as causas dos pontos quentes nas termografias. Os contornos das áreas facilitam a análise das avarias e a determinação das suas causas. Além das fitas isolantes que criaram pontos quentes propositais, também se nota que havia sujeira depositada no meio do equipamento e a presença de sombreamento devido à estrutura do local. Os elementos citados são responsáveis por dissipar energia na forma de calor e danificar o equipamento. Sendo assim, a metodologia proposta neste trabalho mostrou-se capaz de identificar as avarias em cima dos módulos fotovoltaicos e possibilitou investigar as causas dos problemas nos equipamentos.

5 Conclusão

A localização de avarias em módulos fotovoltaicos é fundamental para a manutenção do sistema e a preservação dos equipamentos. Negligenciar esse problema leva à diminuição da produção de energia e à queda na eficiência. A análise por registros termográficos permite extrair o perfil de temperaturas dos equipamentos, denunciar pontos de não uniformidade. Neste trabalho, o processamento das imagens coletadas passou por diversas etapas, incluindo segmentação, filtragem, processamento e demarcações, o que permitiu localizar os pontos quentes.

Desenvolveu-se neste trabalho uma metodologia para localização de avarias em cima de módulos fotovoltaicas de forma passiva que se utilizou de informações das termografias dos equipamentos, computação via nuvem para treinamento de rede neural e processamentos de imagem, para assim demarcar os pontos quentes com acurácia. Os resultados obtidos na etapa de localização das avarias mostraram que as técnicas aplicadas foram capazes de localizar os elementos correspondentes aos pontos quentes em cima dos módulos, logo localizou as avarias em cima dos painéis como proposto.

O trabalho proposto pretende atender as necessidades de análises passivas em sistemas fotovoltaicos de quaisquer dimensões. A versatilidade do método, aplica-se em centrais residenciais e rurais, as quais possuem poucos módulos, quanto que também a grandes instalações fotovoltaicas para a produção de energia em escala de geração. A partir de um drone com uma câmera térmica instalada, ou um operador com o equipamento, como o caso deste trabalho, a captura de termografias para o uso dos processamentos especificados, é capaz de localizar os *hotspots* nos módulos fotovoltaicos para que sejam investigadas as causas do problema.

A utilização de um setup de teste, permitiu a criação de um *dataset* dos módulos e treinar da rede neural do modelo YOLOv8 com uma precisão de 95% para detecção dos equipamentos nas termografias, o que evitou que outras partes da imagem com temperaturas elevadas fossem analisadas. A aplicações dos processamentos de imagens: O filtro gaussiano para retirar ruídos das imagens e manter o formato das bordas térmicas; A segmentação por *threshold* de espaço

de cor HSV a fim de separar as regiões com maior temperatura do restante do conjunto; os processos de fechamento e abertura binários os quais favoreceram a análise, ao ajustar e corrigir erros do processo anterior. Possibilitaram uma separação e demarcação clara das áreas com *hotspots* dos equipamentos. A demarcação das camadas dos pontos segmentados possibilitou a localização das avarias na imagem original, levando a encontrar as origens desses defeitos no módulo, o que contribui para validar a metodologia aqui proposta, pois além das fitas isolantes colocadas, também foram identificados outros elementos que afetavam os módulos.

Por fim, se forem seguidas as etapas de procedimento computacional apresentado neste trabalho, podem-se analisar outros sistemas fotovoltaicos, de modo a localizar suas avarias e suas origens nos painéis. Com essas informações, podem ser tomadas medidas para resolver esses problemas.

Para trabalhos futuros, os códigos desenvolvidos podem ser compilados e ajustados como um único *software* que carregue os *datasets* e pesos dos treinamentos da rede neural, para que pode ser feito a localização das avarias de forma automatizada.

6 Referências

- (Abdelsattar, Abdelmoety and Emad-Eldeen, 2023) "A Review on Detection of Solar PV Panels Failures Using Image Processing Techniques," 2023 24th International Middle East Power System Conference, MEPCON 2023 [Preprint], viewed 9 May 2025, Available at: <https://doi.org/10.1109/MEPCON58725.2023.10462371>.
- (Abhijith *et al.*, 2020b) "Farm-Copter: Computer Vision Based Precision Agriculture," 4th International Conference on Computer, Communication and Signal Processing, ICCSP 2020 [Preprint], viewed 10 April 2025, Available at: <https://doi.org/10.1109/ICCCSP49186.2020.9315239>.
- (Afifah *et al.*, 2020) "Hotspot Detection in Photovoltaic Module using Otsu Thresholding Method," 2020 IEEE International Conference on Communication, Networks and Satellite, Comnetsat 2020 - Proceedings, pp. 408–412, viewed 19 May 2025, Available at: <https://doi.org/10.1109/COMNETSAT50391.2020.9328987>.
- (Alqahtani, Almutared and Alzahrani, 2023) "Photovoltaic Hot Spot Detection System Using Deep Convolution Neural Networks," 2023 International Future Energy Electronics Conference, IFEEC 2023, pp. 327–330, viewed 15 June 2025, Available at: <https://doi.org/10.1109/IFEEC58486.2023.10458570>.
- (Bhairnallykar and Narawade, 2023b) "Exploration of Image Segmentation: A Comprehensive Review of Traditional Segmentation Techniques," 2023 7th International Conference on Electronics, Materials Engineering and Nano-Technology, IEMENTech 2023 [Preprint]. viewed 15 June 2025 Available at: <https://doi.org/10.1109/IEMENTECH60402.2023.10423439>.
- (Binti Ishak *et al.*, 2023) "Hotspot Detection of Solar Photovoltaic System: A Perspective from Image Processing," 2023 IEEE 3rd International Conference in Power Engineering Applications: Shaping Sustainability Through Power Engineering Innovation, ICPEA 2023, pp. 263–267. viewed 5 April 2025 Available at: <https://doi.org/10.1109/ICPEA56918.2023.10093148>.
- (Chattopadhyay *et al.*, 2018) "Correlating infrared thermography with electrical degradation of PV modules inspected in all-india survey of photovoltaic module reliability 2016," IEEE Journal of Photovoltaics, 8(6), pp. 1800–1808. viewed 4 June 2025 Available at: <https://doi.org/10.1109/JPHOTOV.2018.2859780>.

- (Chen, Li and Ling, 2020) "Hot-Spot Detection for Thermographic Images of Solar Panels," Proceedings of the 32nd Chinese Control and Decision Conference, CCDC 2020, pp. 4651–4655. viewed 18 May 2025 Available at: <https://doi.org/10.1109/CCDC49329.2020.9164255>.
- (Chen *et al.*, 2023) "A Hot Spot Detection Method of Photovoltaic Module Based on Image Semantic Segmentation," 2023 IEEE 6th International Electrical and Energy Conference, CIEEC 2023, pp. 837–841. viewed 25 April 2025 Available at: <https://doi.org/10.1109/CIEEC58067.2023.10167018>.
- (Gargouri and Haddeji, 2024) "Implementation of a Photovoltaic Default Detection System using Deep Learning," pp. 1–5. viewed 9 April 2025 Available at: https://doi.org/10.1109/IC_ASET61847.2024.10596189.
- (Glavaš *et al.*, 2017) "Infrared thermography in inspection of photovoltaic panels," Proceedings of International Conference on Smart Systems and Technologies 2017, SST 2017, 2017-December, pp. 63–68. viewed 21 April 2025 Available at: <https://doi.org/10.1109/SST.2017.8188671>.
- (Guerriero and Daliendo, 2017) "Automatic edge identification for accurate analysis of thermographic images of solar panels," 2017 6th International Conference on Clean Electrical Power: Renewable Energy Resources Impact, ICCEP 2017, pp. 768–772. viewed 10 April 2025 Available at: <https://doi.org/10.1109/ICCEP.2017.8004778>.
- (Hajjdiab *et al.*, 2023) "Automated Computer Vision-based Detection of Solar Panel Defects Using a Thermal Camera Mobile Application," Proceedings - 2023 International Conference on Future Internet of Things and Cloud, FiCloud 2023, pp. 410–415. viewed 7 May 2025. Available at: <https://doi.org/10.1109/FICLOUD58648.2023.00066>.
- (He, 2019) "Video based fire detection in photovoltaic system," Proceedings - 2019 4th International Conference on Mechanical, Control and Computer Engineering, ICMCCE 2019, pp. 289–293. Available at: <https://doi.org/10.1109/ICMCCE48743.2019.00072>.
- (Hocaoglu *et al.*, 2018) "Comparison of experimentally obtained I-V curves of different PV modules," 2018 9th International Renewable Energy Congress, IREC 2018, pp. 1–4. viewed 5 May 2025 Available at: <https://doi.org/10.1109/IREC.2018.8362472>.
- (Hu *et al.*, 2024) "Aerial Photovoltaic Panel Infrared Image Defect Detection Method Based on Improved YOLOv8," 2024 9th International Conference on Intelligent Computing and Signal Processing, ICSP 2024, pp. 1777–1780. viewed 19 April

- 2025 Available at:
<https://doi.org/10.1109/ICSP62122.2024.10743577>.
- (Hussain and Agarwal, 2016) “Artifacts removal in LBP based flame edges using binary morphology,” Proceedings of 2015 International Conference on Signal Processing, Computing and Control, ISPC 2015, pp. 184–189. viewed 10 May 2025 Available at:
<https://doi.org/10.1109/ISPC.2015.7375022>.
- (IEA, 2024) International Energy Agency (IEA). (2024) *Renewables 2024: Analysis and forecast to 2030*. viewed 4 March 2025 Available at: <https://www.iea.org/reports/renewables-2024>
- (Islam *et al.*, 2019) “Infrared Thermography Based Performance Analysis of Photovoltaic Modules,” International Conference on Energy and Power Engineering: Power for Progress, ICEPE 2019 [Preprint]. viewed 14 April 2025 Available at:
<https://doi.org/10.1109/CEPE.2019.8726565>.
- (Kazmerski, Kurtz and Vasi, 2024) “Photovoltaics: Impact on People and Society,” IEEE Electron Devices Magazine, 2(3), pp. 6–15. viewed 25 May 2025 Available at:
<https://doi.org/10.1109/MED.2024.3396614>.
- (Liu *et al.*, 2024) “Based on the improved YOLOv8 photovoltaic module defect detection method,” 2024 6th International Conference on Energy, Power and Grid, ICEPG 2024, pp. 374–377. viewed 21 April 2025. Available at:
<https://doi.org/10.1109/ICEPG63230.2024.10775607>.
- (Liu *et al.*, 2025) “Intelligent Detection System for Dirty Photovoltaic Panels Based on YOLOv8,” 2025 IEEE International Conference on Mechatronics and Automation (ICMA), pp. 199–203. viewed 15 June 2025 Available at:
<https://doi.org/10.1109/ICMA65362.2025.11120764>.
- (Liu and Song, 2024) “A Temperature Detection Method for Electrical Equipment Based on Infrared Thermal Image,” 2024 2nd International Conference on Cyber-Energy Systems and Intelligent Energy, ICCSIE 2024 [Preprint]. viewed 6 June 2025 Available at:
<https://doi.org/10.1109/ICCSIE61360.2024.10698258>.
- (Mazen, Seoud and Shaker, 2023) “Deep Learning for Automatic Defect Detection in PV Modules Using Electroluminescence Images,” IEEE Access, 11, pp. 57783–57795. viewed 16 May 2025 Available at:
<https://doi.org/10.1109/ACCESS.2023.3284043>.
- (Montanez *et al.*, 2020) “Photovoltaic module segmentation and thermal analysis tool from thermal images,” 2020 IEEE International Autumn Meeting on Power, Electronics and Computing, ROPEC 2020

- [Preprint]. viewed 20 April 2025 Available at: <https://doi.org/10.1109/ROPEC50909.2020.9258760>.
- (Moradi Sizkouhi *et al.*, 2019) “Autonomous Path Planning by Unmanned Aerial Vehicle (UAV) for Precise Monitoring of Large-Scale PV plants,” Conference Record of the IEEE Photovoltaic Specialists Conference, pp. 1398–1402. viewed 7 June 2025 Available at: <https://doi.org/10.1109/PVSC40753.2019.8980862>.
- (Ngo and Macabebe, 2017) Image segmentation using K-means color quantization and density-based spatial clustering of applications with noise (DBSCAN) for hotspot detection in photovoltaic modules,” IEEE Region 10 Annual International Conference, Proceedings/TENCON, pp. 1614–1618. viewed 5 April 2025 Available at: <https://doi.org/10.1109/TENCON.2016.7848290>.
- (De Oliveira *et al.*, 2021) “Evaluation of Faults in a Photovoltaic Power Plant using Orthomosaics based on Aerial Infrared Thermography,” Conference Record of the IEEE Photovoltaic Specialists Conference, pp. 2604–2610. viewed 1 April 2025 Available at: <https://doi.org/10.1109/PVSC43889.2021.9518541>.
- (Packa *et al.*, 2016) “Chosen diagnostic methods of photovoltaic modules,” Proceedings of International Conference DEMISEE 2016: Diagnostic of Electrical Machines and Insulating Systems in Electrical Engineering, pp. 29–33. viewed 9 May 2025 Available at: <https://doi.org/10.1109/DEMISEE.2016.7530481>.
- (Pathak and Patil, 2023) “Evaluation of Effect of Pre-Processing Techniques in Solar Panel Fault Detection,” IEEE Access, 11, pp. 72848–72860. viewed 1 June 2025 Available at: <https://doi.org/10.1109/ACCESS.2023.3293756>.
- (Phan and Nguyen, 2023) “A Novel Approach for PV Cell Fault Detection Using YOLOv8 and Particle Swarm Optimization,” Midwest Symposium on Circuits and Systems, pp. 634–638. viewed 10 June 2025 Available at: <https://doi.org/10.1109/MWSCAS57524.2023.10406139>.
- (Rubanenko *et al.*, 2024) “Determining Probable Locations of Photovoltaic Modules Malfunctions,” 2024 IEEE 4th International Conference on Sustainable Energy and Future Electric Transportation, SEFET 2024 [Preprint]. viewed 4 May 2025 Available at: <https://doi.org/10.1109/SEFET61574.2024.10717959>.
- (Serfa Juan and Kim, 2020) “Photovoltaic Cell Defect Detection Model based-on Extracted Electroluminescence Images using SVM Classifier,” 2020 International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2020,

- pp. 578–582. viewed 28 April 2025 Available at:
<https://doi.org/10.1109/ICAIC48513.2020.9065065>.
- (Tajwar *et al.*, 2021) “Infrared Thermography Based Hotspot Detection of Photovoltaic Module using YOLO,” Proceedings of the Energy Conversion Congress and Exposition - Asia, ECCE Asia 2021, pp. 1542–1547. viewed 25 May 2025 Available at:
<https://doi.org/10.1109/ECCE-ASIA49820.2021.9478998>.
- (Wang *et al.*, 2018) “Quantitative analysis on mathematical morphology,” Proceedings of the International Conference on Anti-Counterfeiting, Security and Identification, ASID, 2018-November, pp. 103–106. viewed 10 May 2025 Available at:
<https://doi.org/10.1109/ICASID.2018.8693120>.
- (Wang *et al.*, 2024) “An Enhanced YOLOv8 Network Combined with Model Pruning for Defect Detection in Solar Cell Images,” 2024 IEEE 8th International Conference on Vision, Image and Signal Processing, ICVISP 2024 [Preprint]. viewed 1 April 2025 Available at:
<https://doi.org/10.1109/ICVISP64524.2024.10959386>.
- (Wang *et al.*, 2021) “Effective Segmentation Approach for Solar Photovoltaic Panels in Uneven Illuminated Color Infrared Images,” IEEE Journal of Photovoltaics, 11(2), pp. 478–484. viewed 2 May 2025 Available at:
<https://doi.org/10.1109/JPHOTOV.2020.3041189>.
- (Xu, Zhou and Fei, 2014) “Detection methods for micro-cracked defects of photovoltaic modules based on machine vision,” CCIS 2014 - Proceedings of 2014 IEEE 3rd International Conference on Cloud Computing and Intelligence Systems, pp. 609–613. viewed 4 May 2025 Available at:
<https://doi.org/10.1109/CCIS.2014.7175807>.
- (Xu *et al.*, 2021) “A Segmentation Method for PV Modules in Infrared Thermography Images,” Asia-Pacific Power and Energy Engineering Conference, APPEEC, 2021-November. viewed 5 June 2025 Available at:
<https://doi.org/10.1109/APPEEC50844.2021.9687630>.
- (Yang, Chen and Kang, 2021b) “A Temperature Monitoring Method for Power Electronic Converter Based on Infrared Image and Object Detection Algorithm,” Proceedings of 2021 IEEE 4th International Electrical and Energy Conference, CIEEC 2021 [Preprint]. viewed 10 May 2025 Available at:
<https://doi.org/10.1109/CIEEC50170.2021.9510854>.
- (Yu, Zhao and Wang, 2008) “Research advances and prospects of mathematical morphology in image processing,” 2008 IEEE International Conference on Cybernetics and Intelligent Systems, CIS

2008, pp. 1242–1247. viewed 10 May 2025 Available at:
<https://doi.org/10.1109/ICCIS.2008.4670786>.

(Zefri *et al.*, 2022)

“An Encoder-Decoder U-Net Based Model for Overheated Photovoltaic Modules Extraction from Orthorectified Remotely Sensed Thermal Infrared UAV Imagery,” 2022 IEEE Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, M2GARSS 2022 - Proceedings, pp. 25–28. viewed 5 April 2025 Available at:
<https://doi.org/10.1109/M2GARSS52314.2022.9840254>.

(Zhang, 2009)

“Extended closing operation in morphology and its application in image processing,” Proceedings - 2009 International Conference on Information Technology and Computer Science, ITCS 2009, 1, pp. 83–87. viewed 10 June 2025 Available at: <https://doi.org/10.1109/ITCS.2009.268>.

(Zhang *et al.*, 2022)

“Photovoltaic Hot Spot Fault Warning and Treatment Method Based on Image Processing,” 2022 4th International Conference on Smart Power and Internet Energy Systems, SPIES 2022, pp. 2339–2343. viewed 26 March 2025 Available at: <https://doi.org/10.1109/SPIES55999.2022.10082359>.

(Zhao *et al.*, 2025)

“A YOLOv8-Based Model for Hot-Spot Detection in Photovoltaic Systems,” 2025 IEEE 7th International Conference on Communications, Information System and Computer Engineering, CISCE 2025, pp. 809–812. viewed 20 March 2025. Available at:
<https://doi.org/10.1109/CISCE65916.2025.11065278>.

DECLARAÇÃO DE INTEGRIDADE

DECLARAÇÃO DE INTEGRIDADE

Declaro ter conduzido este trabalho académico com integridade. Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à sua elaboração.

Declaro que o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

ISEP, Porto, 25 de Setembro de 2025



Victor Farjawi