

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Segmentação Semântica e Diagnóstico
Automatizado de Anomalias Térmicas em Painéis
Elétricos utilizando Deep Learning e Espaço de Cor
CIELAB.**

Leandro De Andrade

Monografia - MBA em Ciência de Dados (CEMEAI)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Leandro De Andrade

Segmentação Semântica e Diagnóstico Automatizado de Anomalias Térmicas em Painéis Elétricos utilizando Deep Learning e Espaço de Cor CIELAB.

Monografia apresentada ao Centro de Ciências Matemáticas Aplicadas à Indústria do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Ciências de Dados.

Área de concentração: Ciências de Dados

Orientador: Prof. Dr. Afonso Paiva Neto

Versão original

São Carlos

2026

Leandro De Andrade

Segmentação Semântica e Diagnóstico Automatizado de Anomalias Térmicas em Painéis Elétricos utilizando Deep Learning e Espaço de Cor CIELAB.

Monografia apresentada ao Centro de Ciências Matemáticas Aplicadas à Indústria do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Ciências de Dados.

Área de concentração: Ciências de Dados

Orientador: Prof. Dr. Afonso Paiva Neto

Versão original

São Carlos

2026

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

A553s Andrade, Leandro De
Segmentação Semântica e Diagnóstico Automatizado
de Anomalias Térmicas em Painéis Elétricos
utilizando Deep Learning e Espaço de Cor CIELAB. /
Leandro De Andrade; orientador Afonso Paiva Neto. --
São Carlos, 2026.
63 p.

Trabalho de conclusão de curso (MBA em Ciência de
Dados) -- Instituto de Ciências Matemáticas e de
Computação, Universidade de São Paulo, 2026.

1. CE610.4.1.4X. 2. CE626.11.2. 3. CB330.3.5.3.5.
4. CE624.15.1. 5. CE610.4.1.4. I. Paiva Neto,
Afonso, orient. II. Título.

*Este trabalho é dedicado a minha mãe Juraci, minha esposa Bárbara e ao meu filho Lucas.
Sem eles, tal trabalho não teria a necessária motivação e empenho.*

AGRADECIMENTOS

Agradeço a Deus por mais esta etapa em minha jornada.

Agradeço fortemente ao Professor Afonso Paiva pelos inúmeros conselhos e direcionamentos ao longo deste estudo.

Agradeço ao colega e amigo Eduardo Souza pelos questionamentos e sugestões dadas.

Agradeço aos meu colegas deste MBA, nos quais pude me apoiar.

“Sinto que não estou apenas sendo reformado, mas transformado.”

Sêneca

RESUMO

Andrade, L **Diagnóstico Automatizado de Termografia em Painéis Elétricos via U-Net**. 2026. 64 p. Monografia (MBA em Ciências de Dados) - Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2026.

A termografia infravermelha consolidou-se como uma técnica fundamental na manutenção preditiva de sistemas elétricos industriais, permitindo a identificação remota de anomalias térmicas. Contudo, a eficácia dessa inspeção é frequentemente limitada pela subjetividade da análise manual e pela variabilidade na representação visual dependente de paletas de cores proprietárias. Este trabalho apresenta o desenvolvimento e validação de um sistema automatizado para segmentação e diagnóstico de falhas térmicas em componentes críticos como bornes, disjuntores e relés. A metodologia proposta integra uma rede neural convolucional com arquitetura U-Net, otimizada via *Transfer Learning* com *MobileNetV2*, a um método diferenciado de pré-processamento de imagens no espaço de cor CIELAB. Ao isolar o canal de luminância (L^*), o sistema estabelece um mapeamento linear e perceptualmente uniforme da temperatura (10°C a 110°C), eliminando ambiguidades visuais. Os resultados experimentais, obtidos a partir de um *dataset* próprio, demonstraram a eficácia do modelo na localização das Regiões de Interesse (ROI), com destaque para o desempenho na segmentação de componentes com geometria definida, como relés (Coeficiente de Dice de 0.85). O sistema automatizado foi capaz de extrair a temperatura máxima e classificar a severidade das falhas com base nos critérios normativos do *Infraspection Institute* e NETA, oferecendo um diagnóstico padronizado e contribuindo para a segurança operacional.

Palavras-chave: Termografia Infravermelha, Segmentação Semântica, Manutenção Preditiva, Deep Learning, Espaço de Cor CIELAB, U-Net.

ABSTRACT

Andrade, L **Automated Thermography Diagnosis in Electrical Panels using U-Net**. 2026. 64 p. Monograph (MBA in Data Sciences) - Centro de Ciências Matemáticas Aplicadas à Indústria, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2026.

Infrared thermography has become established as a fundamental technique in the predictive maintenance of industrial electrical systems, enabling the non-contact identification of thermal anomalies. However, the effectiveness of this inspection is often limited by the subjectivity of manual analysis and the variability in visual representation caused by proprietary color palettes. This work presents the development and validation of an automated system for the segmentation and diagnosis of thermal faults in critical components such as terminals, circuit breakers, and relays. The proposed methodology integrates a convolutional neural network with a U-Net architecture, optimized via Transfer Learning with MobileNetV2, with a distinctive image preprocessing method in the CIELAB color space. By isolating the luminance channel (L^*), the system establishes a linear and perceptually uniform temperature mapping (10°C to 110°C), eliminating visual ambiguities. Experimental results, obtained from a custom dataset, demonstrated the model's effectiveness in locating Regions of Interest (ROI), particularly regarding performance in segmenting components with well-defined geometry, such as relays (Dice Coefficient of 0.85). The automated system successfully extracted the maximum temperature and classified fault severity based on the standard criteria of the Infrasppection Institute and NETA, providing a standardized diagnosis and contributing to operational safety.

Keywords: Infrared Thermography, Semantic Segmentation, Predictive Maintenance, Deep Learning, CIELAB Color Space, U-Net.

LISTA DE FIGURAS

Figura 1 – Quadro de luz visto no espectro de luz visível.	23
Figura 2 – Quadro de luz visto no espectro de luz infravermelha.	24
Figura 3 – Espectro eletromagnético.	28
Figura 4 – Relação entre temperatura e comprimento de onda.	28
Figura 5 – Contator energizado interferindo na temperatura dos componentes ao redor.	29
Figura 6 – Efeito <i>Spot size</i>	30
Figura 7 – Ilustração do espaço de cor CIELAB.	32
Figura 8 – Estrutura U-Net.	34
Figura 9 – Termovisor Fluke Ti25.	37
Figura 10 – Termovisor Flir C2.	37
Figura 11 – Imagem com os resultados publicados pelos autores do artigo.	42
Figura 12 – Primeira amostra.	45
Figura 13 – Segunda amostra.	46
Figura 14 – Objeto de interesse - BORNE.	47
Figura 15 – Objeto de interesse - DISJUNTOR.	47
Figura 16 – Objeto de interesse - RELÉ.	47
Figura 17 – Métricas de treino e validação do modelo.	51
Figura 18 – Imagem com Componentes segmentados.	52
Figura 19 – Matriz de confusão.	54
Figura 20 – Irregularidades na detecção de bordas.	55
Figura 21 – Sensibilidade à iluminação.	55
Figura 22 – Alucinação.	56
Figura 23 – Respostas do sistema ao analisar algumas amostras.	57
Figura 24 – Comparativo visual: Termografia Padrão vs. Visualização Aprimorada.	59

LISTA DE TABELAS

Tabela 1 – Publicações de referência	44
Tabela 2 – Parâmetros para a definição de defeito e sua criticidade.	50
Tabela 3 – Desempenho Por Componente.	53

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Objetivos	25
1.2	Organização do trabalho	25
2	REFERENCIAL TEÓRICO	27
2.1	Termografia Infravermelha	27
2.2	Segmentação Semântica e Processamento de imagens	30
2.2.1	Espaços de Cor e Percepção Visual	32
2.3	Aprendizado de Máquina e Aprendizado Profundo para Segmentação Semântica	32
2.4	Métricas de Avaliação para Segmentação	35
2.5	Datasets para Análise de Imagens Térmicas	36
2.6	Transfer learning	38
2.7	Trabalhos relacionados	38
3	DESENVOLVIMENTO	45
3.1	Obtenção e tratamento dos dados.	45
3.2	Implementação do Pré-processamento de Imagens	48
3.3	Construção do modelo.	48
3.4	Aplicação do modelo	49
4	RESULTADOS	51
4.1	Desempenho do modelo de segmentação.	51
4.2	Desempenho por componente	53
4.3	Análise das limitações e casos de falha	54
4.4	Diagnóstico Térmico Automatizado	56
4.5	Qualidade da Visualização e Suporte à Decisão Humana	58
5	CONCLUSÃO	61
	REFERÊNCIAS	63

1 INTRODUÇÃO


Dentro do contexto da produção em larga escala a manutenção dos sistemas de produção tem relevância direta na capacidade de produção sendo um dos principais fatores a se levar em consideração quando o objetivo é competitividade, pois apenas poucos minutos de produção perdidos podem significar retrabalho ou até mesmo a perda de lotes do produto produzido.

Tendo isto em vista, técnicas de inspeção de máquinas para a predição de falhas passam a ocupar o posto de maior importância dentro da manutenção dos equipamentos como fator chave para planejamentos precisos das manutenções programadas objetivando a mínima intervenção nos equipamentos e maximizando a eficiência dos equipamentos e processos.

Para a predição de falhas de equipamentos há um grande rol de técnicas e dispositivos que permitem que seja acompanhada a deterioração dos equipamentos, e uma das técnicas de maior destaque é a inspeção termográfica onde o mantenedor consegue enxergar a condição da máquina em funcionamento sem que seja exposto a perigos e sem impactar na produção, trazendo dados valiosos para identificar com precisão pontos críticos que por muitas vezes não seriam percebidos mesmo com uma intervenção direta nos equipamentos.

Um dos defeitos mais comuns e mais críticos em sistemas elétricos são conexões elétricas deficientes que silenciosamente provocam sobreaquecimento dos cabos e dispositivos de controle ilustradas nas Figuras 1 e 2 podendo levar a ruptura destas conexões, e em casos mais extremos até mesmo a incêndios, provocando perdas enormes na produção tendo em vista que muitos destes painéis tem por função o processamento e controle das ações de uma máquina ou até mesmo de toda uma fábrica.

Figura 1 – Quadro de luz visto no espectro de luz visível.



Fonte: Autor.

Figura 2 – Quadro de luz visto no espectro de luz infravermelha.



Fonte: Autor.

Para a mitigação de tais defeitos, a técnica mais eficiente é a análise de imagens térmicas que, embora seja eficiente, possui algumas limitações que impactam na sua eficiência. As limitações vão de subjetividade na leitura das imagens que dependem da experiência do operador do instrumento e o custo do processamento (homem hora) para a análise e elaboração de relatórios para as equipes de planejamento.

Devido a importância da inspeção por termografia, é importante reduzir suas limitações e, principalmente, romper a barreira da expertise humana, pois os funcionários que operam tais equipamentos podem se ausentar de suas funções por diversos fatores, e tais situações podem interferir, mesmo que indiretamente, no funcionamento de toda a fábrica. Por este motivo, é de grande importância desenvolver um sistema que automatize tal tarefa e a padronize para que o planejamento das manutenções seja mais ágil e assertivo.

Dada a necessidade, entram os sistemas de aprendizado de máquina para suprir esta deficiência e a segmentação semântica de imagens é capaz de identificar tais anomalias retratadas nas imagens de forma automática tendo em vista que é possível identificar componentes, conexões e apontar os locais onde a temperatura é mais elevada comparando a temperatura destes pontos com parâmetros previstos em normas técnicas.

1.1 Objetivos

O objetivo geral deste trabalho é identificar de forma automática através da segmentação de imagens infravermelhas os diferentes pontos de aquecimento em painéis elétricos e automatizar a tomada de decisão no planejamento das manutenções dos sistemas elétricos de instalações industriais.

Para alcançar tal objetivo, serão seguidas as seguintes etapas:

1. Estudar os modelos de segmentação semântica de imagens aplicáveis a dados térmicos;
2. Comparar diferentes arquiteturas de modelos de segmentação para definir a mais adequada para imagens térmicas de painéis elétricos;
3. Adquirir ou selecionar um conjunto de dados de imagens térmicas e realizar o pré-processamento e anotação necessários;
4. Implementar e treinar o modelo de segmentação selecionado, utilizando técnicas como *transfer learning*, se apropriado, para adaptar um modelo pré-treinado à tarefa específica;
5. Avaliar o desempenho do modelo desenvolvido em um conjunto de dados de teste, utilizando métricas apropriadas para segmentação (e.g., *Dice - Dice Coefficient*);
6. Aplicar a metodologia e o modelo treinado em um conjunto de dados representativo de um cenário real (se possível).

1.2 Organização do trabalho

Este trabalho está estruturado em cinco capítulos. O Capítulo 1 introduz o tema, a problemática e os objetivos da pesquisa. O Capítulo 2 apresenta a fundamentação teórica necessária para sustentar o desenvolvimento da proposta. No Capítulo 3, detalha-se a metodologia empregada, com foco no pré-processamento das imagens e na técnica de mapeamento de temperatura via separação do canal de luminância no espaço de cor CIELAB. O Capítulo 4 é dedicado à análise dos resultados, discutindo o desempenho global do modelo e as métricas individuais por classe, como acurácia e o coeficiente *Dice*, para a identificação de *hotspots*. Por fim, o Capítulo 5 condensa as conclusões alcançadas e propõe sugestões de melhoria para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Este Capítulo estabelece os fundamentos teóricos necessários para a compreensão da solução proposta. São abordados os princípios da termografia infravermelha e sua aplicação na manutenção preditiva industrial, seguidos por uma análise técnica do espaço de cor CIELAB e sua importância na linearidade do mapeamento térmico. Por fim, apresentam-se modelos de destaque em Redes Neurais Convolucionais (CNNs) e segmentação semântica, com foco na arquitetura U-Net.

2.1 Termografia Infravermelha


A radiação infravermelha faz parte do espectro eletromagnético (Figura 3) entre a luz visível e as micro-ondas. Sua principal característica é que qualquer objeto com temperatura acima do zero absoluto emite radiação infravermelha que é diretamente associada a temperatura, onde quanto mais radiação um corpo emite, maior é a sua temperatura e maior é o comprimento da onda infravermelha (Figura 4). Dessa forma, a medição dos raios infravermelhos baseia a técnica de termografia captando situações que não podem ser observadas pela visão humana utilizando câmeras especiais que podem determinar quanto uma superfície emite de radiação e em qual comprimento de onda, traduzindo estes sinais em imagens térmicas, sem contato.

Figura 3 – Espectro eletromagnético.



Fonte: <https://www.fractal.com/pt-br/manutenpedia/aplicacao-da-termografia-infravermelha-em-equipamentos-industriais>.

Figura 4 – Relação entre temperatura e comprimento de onda.



Fonte: <https://www.infratec-infrared.com/thermography/service-support/glossary/theory/>.

A proporção da radiação emitida por uma superfície é descrita como emissividade. A emissividade varia de zero até um e depende de fatores diversos, como por exemplo o

material do objeto medido, a condição da sua superfície (lisa, polida, oxidada, pintada ou áspera) e o ângulo de visão. Geralmente superfícies polidas tem baixa emissividade enquanto superfícies foscas ou oxidadas tendem a ter alta emissividade.

A refletividade (R) é a proporção da radiação vinda de outros objetos no entorno do ponto de medição. Ele é inversamente proporcional a emissividade (ε), segundo a relação $R = 1 - \varepsilon$. Quanto menor é a emissividade maior é a refletividade. Este fenômeno interfere nas medições de temperatura, pois a câmera capta a radiação refletida de fontes próximas (como indutores energizados ao lado de elementos de conexão) demonstrado na Figura 5, mascarando a temperatura real do objeto e dificultando a compreensão do seu estado térmico.


Figura 5 – Contator energizado interferindo na temperatura dos componentes ao redor.



Fonte: Autor.

A atmosfera também é um fator de interferência na medição de temperatura, pois para o espectro infravermelho ela não é transparente como é percebido na luz visível. A atmosfera pode absorver parte da radiação e também pode emitir sua própria radiação influenciada pela temperatura ambiente e pela umidade do ar ou por elementos como fumaça ou poeira. Tudo isso deve ser somado a distância do elemento de medição em relação ao objeto medido.

A acurácia da medição de temperatura por pixel está diretamente ligada à resolução espacial da câmera e ao efeito do tamanho do ponto (spot-size effect). (FLIR Systems, Inc., 2016) Quando um objeto é representado por poucos pixels isto é, uma imagem pequena no sensor, a temperatura medida pode ser influenciada por pixels adjacentes, mascarando a temperatura real do objeto. Para medições confiáveis, o objeto deve cobrir um número mínimo de pixels (idealmente, cerca de 20 pixels de diâmetro) para anular esse efeito. (FLIR Systems, Inc., 2016)

Figura 6 – Efeito *Spot size*.

Fonte: <https://www.flir.com/oem/>.

2.2 Segmentação Semântica e Processamento de imagens

A segmentação de imagens é uma etapa do processamento de imagens cujo objetivo é subdividir uma imagem em regiões ou objetos de modo que possam ser aplicados na resolução do problema que deseja-se resolver. Resumindo, a segmentação de imagens isola objetos ou regiões de interesse permitindo a análise destas partes (Gonzales, 2013). Um exemplo de aplicação desta técnica é a segmentação de áreas de aquecimento em conexões elétricas.

Segmentação para detecção de bordas

O método de detecção de bordas busca mudanças bruscas na intensidade das imagens que são interpretadas como contornos. Para isso, ele utiliza o cálculo de derivadas de primeira e segunda ordem da função de intensidade da imagem, onde as derivadas de primeira ordem representadas pelo gradiente são aplicadas na identificação da força e a variação da intensidade da borda, gerando um vetor que aponta para a maior taxa de variação. (Gonzales, 2013) Operadores de máscaras de filtragem espacial como Roberts, Prewitt e Sobel são usados para aproximar essas derivadas apontando as descontinuidades.

As derivadas de segunda ordem, como o operador Laplaciano atuam identificando pequenos detalhes e descontinuidades fortalecendo esses elementos, mas também amplifica ruídos presentes na imagem. Para resolver esse problema o operador Laplaciano da Gaussiana (LoG) combina uma etapa de suavização com a detecção de bordas reduzindo a sensibilidade ao ruído. Buscando melhorar a otimização, o detector de Canny foi desenvolvido com os objetivos de alcançar uma baixa taxa de erros garantindo uma boa localização das bordas e fornecendo uma resposta de ponto único. Para atingir esses resultados o algoritmo executa um processo multifásico que inclui a suavização da imagem, o cálculo da magnitude e direção do gradiente, a supressão de não máximos e, uma

limiarização por histerese.

Segmentação por similaridade

A segmentação por similaridade é uma abordagem que agrupa sub-regiões de uma imagem com base em propriedades semelhantes de acordo com critérios previamente definidos (Géron, 2019). Uma das principais técnicas dentro dessa abordagem é a limiarização que agrupa pixels ou sub-regiões que compartilham características comuns. Existem diversas variações deste método como por exemplo a limiarização global simples que aplica um único limiar a toda a imagem, há também a limiarização global ótima (método Otsu) que determina o limiar ideal ao maximizar a variância entre classes baseado no histograma. Há também a limiarização adaptativa que utiliza limiares dinâmicos que se ajustam conforme as características locais da imagem como a média e o desvio da vizinhança.

Além da limiarização, existem outras técnicas de segmentação por similaridade, como o crescimento de região por exemplo que inicia o processo a partir de "pontos semente" e anexa pixels vizinhos que atendem a um critério de similaridade, como pertencer a uma faixa de cor específica. Outro método é a divisão e fusão de região que primeiro subdivide recursivamente a imagem em áreas menores e em seguida, une as regiões adjacentes que são semelhantes.


Os watersheds morfológicos tratam a imagem como um mapa topográfico onde as linhas de divisão são posicionadas entre as regiões de mínimos de intensidade formando as segmentações. Para evitar a super-segmentação frequentemente usa-se marcadores que incorporam conhecimento prévio sobre os objetos de interesse na imagem.

Processamento de Imagens Coloridas e a Relevância do Espaço CIELAB para Segmentação de imagens térmicas.

A segmentação pode ser aprimorada utilizando informações de cor, visto que há um contraste com o baixo número de tons de cinza. Alguns espaços de cores como o RGB (*Red, Green, Blue*) e HSI (*Hue, Saturation, Intensity*) são empregados para permitir a segmentação baseada em atributos como matiz e saturação. O modelo HSI é reconhecido pela utilidade da segmentação em cor tendo em vista que é possível separar a matiz e a saturação.

Além dos espaços de cor apresentados, destaca-se o espaço de cor *CIELAB*($L^*a^*b^*$) (Figura 7) como um modelo de destaque devido ser perceptualmente uniforme. Isso significa que a distância numérica entre duas tonalidades tem a diferença igualmente perceptível pelo olho humano em qualquer área do espaço de cor. Para as imagens térmicas, este modelo é particularmente útil, pois o CIELAB é um excelente desacoplador da intensidade de cor, permitindo que o canal L seja diretamente mapeado para os valores de temperatura radiométrica.

Figura 7 – Ilustração do espaço de cor CIELAB.



Fonte: <https://www.datacolor.com/pt-br/business-solutions/blog/o-que-e-o-cielab/>.

Trabalhar com o canal L garante que a informação escalar da temperatura seja preservada e processada isoladamente sem que os canais cromáticos (α, β) interfiram no processamento das imagens. O fato do espaço de cor CIELAB ser uniforme perceptualmente facilita o processamento dos algoritmos de aprendizado de máquina, facilitando a interpretação das diferenças de temperatura. A natureza independente de dispositivo do CIELAB garante a padronização na representação e análise dos termogramas, independentemente da câmera térmica ou do sistema de visualização usado.

2.2.1 Espaços de Cor e Percepção Visual

Diferente do espaço RGB, que é orientado a dispositivos, os espaços de cor uniformes como CIELAB e CIELUV buscam modelar a percepção humana. O efeito Helmholtz-Kohlrausch (H-K) descreve o fenômeno onde cores mais saturadas são percebidas como mais brilhantes pelo olho humano, mesmo mantendo a mesma luminância física. Modelos matemáticos, como os propostos por (Nayatani, 1997), buscam quantificar esse efeito para corrigir a luminância em aplicações de processamento de imagem.

2.3 Aprendizado de Máquina e Aprendizado Profundo para Segmentação Semântica

Uma das principais tarefas da visão computacional, a segmentação semântica busca classificar cada pixel de uma imagem atribuindo a uma categoria ou objeto. O uso de técnicas de aprendizado de máquina ou de aprendizado profundo automatiza e torna a compreensão destas imagens mais aprofundada. Mesmo o processamento de imagem sendo anterior às técnicas de aprendizado de máquina e aprendizado profundo, o processamento de imagens fornece as bases conceituais sobre as quais estas tecnologias são construídas.

Um dos objetivos centrais do aprendizado de máquina é o reconhecimento de padrões que tratam da atribuição automática de rótulos a objetos com base em suas características (Gonzales, 2013) onde a informação precisa ser extraída de forma adequada para o processamento computacional antes que a classificação ocorra. Para isto, é necessário que os descritores de fronteira obtenham as características geométricas do objeto como diâmetro, curvatura e comprimento e que os descritores regionais obtenham as propriedades de uma região como perímetro, uniformidade, área e entropia, além de textura (suavidade, rugosidade baseados em histogramas e matrizes de coocorrência).

Uma etapa posterior é a classificação de padrões. Esta etapa envolve atribuir um padrão novo a uma de várias classes predefinidas. Os classificadores estatísticos ótimos (Bayesianos) baseiam-se na probabilidade de um padrão pertencer a uma determinada classe, minimizando a probabilidade de erro. Eles utilizam funções de densidade de probabilidade e podem operar com modelos de classes gaussianas, que definem superfícies de decisão (hiperquadráticas ou lineares) no espaço de características. Já os classificadores de distâncias mínimas usam uma abordagem simples que atribui um padrão à classe cujo protótipo (vetor médio) é mais próximo no espaço de características.

As arquiteturas Convolucionais (CNNs) usam de camadas convolucionais que são muito eficazes para processamento de imagens, aprendendo hierarquias de características automaticamente (desde bordas e texturas de baixo nível até objetos complexos de alto nível). As CNNs estendem esse conceito para aprendizado de características para Segmentação Semântica utilizando arquiteturas como as descritas a seguir:

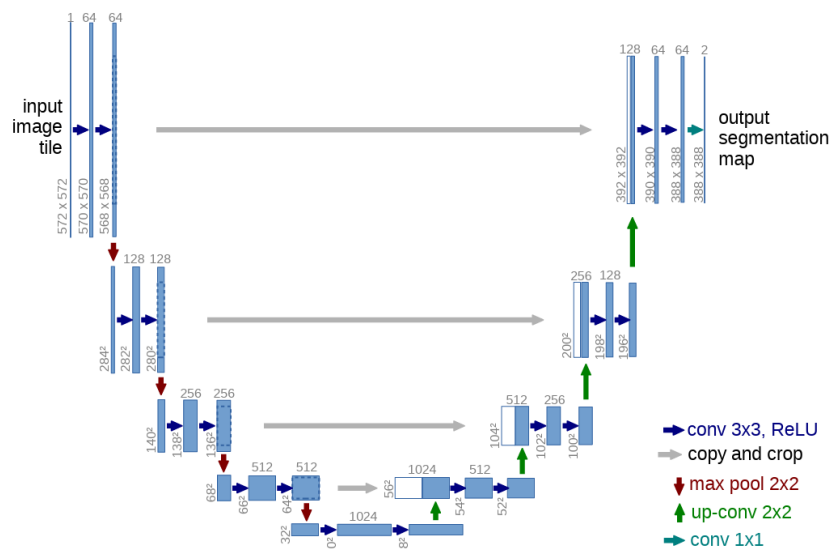
O DeepLabV3+ é uma arquitetura de rede neural para segmentação semântica, que rotula cada pixel da imagem com uma classe. Seu principal objetivo é superar a perda de resolução de *feature maps* e o desafio de segmentar objetos em múltiplas escalas. Ele faz isso utilizando a convolução dilatada permitindo controlar o campo de visão do filtro e a densidade das respostas de features sem aumentar o número de parâmetros.

O modelo emprega dois módulos principais, sendo o primeiro de blocos em cascata com o método *Multi-grid* para taxas dilatadas variáveis e o segundo, *Atrous Spatial Pyramid Pooling (ASPP)* aprimorado. O ASPP melhorado inclui uma normalização em lote (*Batch Normalization*) e *features* em nível de imagem para capturar contexto global e evitar a degeneração do filtro em altas taxas de dilatação (Chen *et al.*, 2017).

A arquitetura U-Net desenvolvida por Ronneberger, Fischer e Brox (Ronneberger; Fischer; Brox, 2015), foi criada inicialmente para aplicação em imagens biomédicas fornecendo resultados precisos mesmo em *datasets* reduzidos. Sua estrutura recebe este nome devido o formato de "U", que pode ser visto na Figura 8, é composta pelos caminhos descritos a seguir:

- Caminho de contração: Funciona como um codificador (*encoder*) resumindo as características da imagem. Isso é feito submetendo a imagem a diversas camadas convolucionais (Conv2D), que atuam como filtros matemáticos que identificam padrões como por exemplo bordas e texturas, seguidas por operações de *downsampling* (redução de resolução para captar informações globais).
- Caminho de expansão: Atua como um decodificador (*decoder*) que permite a o localização exata dos objetos. Ao utilizar convoluções transpostas, o modelo aumenta o mapeamento das características a fim de reconstruir a mascara de segmentação no tamanho original da imagem.
- Conexões de atalho (*Skip Connections*): Em diferenciação a um auto encoder, a U-Net concatena as informações de alta resolução das etapas de (*encoder* diretamente nas camadas de (*decoder*. Isso permite recuperar detalhes finos que seriam perdidos na redução dos dados, preservando-os na predição.

Figura 8 – Estrutura U-Net.



Fonte:(Ronneberger; Fischer; Brox, 2015).

Para a compreensão do treinamento do modelo proposto, definem-se os seguintes conceitos fundamentais:

- ADAM (*Adaptative Moment Estimation*): É um algoritmo de otimização que ajusta de forma dinâmica a taxa de aprendizado acelerando a convergência do modelo ao menor erro possível.
- Épocas: Representa um ciclo completo em que todo o conjunto de dados de treinamento passa pela rede de aprendizado. São necessárias múltiplas épocas para que o

modelo aprenda a generalizar as características ajustando seus erros a medida que o treinamento é realizado.

- Aumento de dados (*Data Augmentation*): Técnica que aplica de forma aleatória deformações nas imagens a fim de aumentar os dados de maneira sintética contornando a limitação de dados nos datasets onde a U-Net é regularmente usada.

2.4 Métricas de Avaliação para Segmentação

A avaliação da qualidade e precisão de um algoritmo de segmentação é um passo importante no processamento digital de imagens onde o objetivo principal da segmentação é subdividir uma imagem em regiões ou objetos constituintes de maneira precisa, e a performance de um algoritmo de segmentação é diretamente medida pela exatidão dessa subdivisão. (Gonzales, 2013)

Critérios de Fidelidade

No contexto de compressão de imagens, os critérios de fidelidade são objetivos para quantificar a "perda de informações" entre uma imagem original e uma versão processada. Essas métricas são diretamente aplicáveis à avaliação da qualidade de uma segmentação ao compará-la com uma referência.

- Erro Quadrático Médio (MSE - Mean Square Error) e Raiz do Erro Quadrático Médio (RMSE - Root Mean Square): Calculam a raiz quadrada da diferença entre os valores dos pixels de duas imagens. Na segmentação, isso pode ser aplicado para medir o "erro" entre a máscara de segmentação gerada e a máscara de referência, quantificando quão semelhantes são as duas imagens pixel a pixel.
- Relação Sinal-Ruído (SNR - Signal-to-Noise Ratio): Embora mais comum para ruído, o SNR relaciona a "potência" do sinal (a imagem original ou a informação relevante) à "potência" do ruído (o erro ou a degradação). Uma segmentação de alta qualidade teria um número de pixels corretamente classificados elevado em relação ao "ruído" (pixels mal classificados).

Classificação e Taxa de Erro (Acurácia de Pixel)

A segmentação pode ser vista como um problema de classificação pixel a pixel, onde cada pixel da imagem é atribuído a uma classe específica. Por exemplo, "objeto de interesse" ou "fundo".

- Minimização da Probabilidade de Erro: O objetivo de classificadores ótimos, como o classificador Bayesiano, é minimizar a probabilidade de classificar incorretamente um padrão, neste caso, um pixel, visando alcançar o valor zero (Gonzales, 2013). Uma

alta acurácia na segmentação corresponde a uma baixa taxa de erro de classificação de pixels.

- **Contagem de Pixels Corretos:** A avaliação direta da performance de um classificador pode ser feita calculando a porcentagem de pixels que foram corretamente classificados em suas respectivas classes (Gonzales, 2013). Para esta métrica, o valor 1 equivale a 100% de acertos.
- **IoU e Dice Coefficient:** Ambas medem a sobreposição entre a máscara de segmentação predita e a máscara real. Para estas métricas, o valor esperado para é 1 o que equivale 100% do desempenho esperado. Elas são quantificações avançadas da "acurácia" e "precisão" de classificação pixel a pixel, indo além do simples número de pixels corretos para considerar a qualidade do contorno e da área. A busca por algoritmos que produzam bordas finas e contínuas e a redução o efeito do tamanho do ponto mostram a importância da sobreposição precisa de áreas.
- **Precisão:** A precisão mede a proporção de resultados identificados por um modelo que são realmente corretos. O valor esperado para a eficiência máxima é 1,0 (ausência de falsos positivos).
- **Revocação (Recall):** A revocação (recall ou sensibilidade), mede a proporção de todas as instâncias positivas relevantes que um modelo conseguiu identificar corretamente. Ela avalia o quão "completos" estão os resultados. Isso significa que o modelo não deixou passar nenhum defeito (Falsos Negativos). O valor ideal de referência é 1.
- **F1-Score:** O F1-score varia de 0 a 1, onde 1 indica o melhor desempenho possível com precisão e revocação perfeitas e 0 indica o pior. É útil em situações em que há um desequilíbrio entre as classes no conjunto de dados, pois considera tanto os falsos positivos quanto os falsos negativos, oferecendo uma avaliação mais abrangente do modelo do que a acurácia simples.

Critérios de Fidelidade Subjetivos (Avaliação Humana)

Em último caso, a qualidade de uma imagem processada, incluindo resultados de segmentação pode ser julgada pela percepção humana (Gonzales, 2013). Especialistas podem avaliar visualmente os resultados da segmentação para verificar se as anomalias térmicas foram corretamente identificadas e delimitadas, e se a representação é útil para a tomada de decisões.

2.5 Datasets para Análise de Imagens Térmicas

Para treinamento e testes do modelo proposto, será utilizado um *dataset* que encontra-se em construção. Atualmente o *dataset* possui aproximadamente 300 pares de

imagens (RGB e Infravermelha). Espera-se que até a conclusão da implementação o *dataset* tenha mais de 600 pares de imagens. As capturas são realizadas com os termovisores Fluke Ti25 Figura 9 (resolução infravermelha de 320 x 240 pixels e RGB de 2 MP) e Flir C2 Figura 10 (resolução infravermelha de 80 x 60 pixels e RGB de 640 x 480 pixels).

Figura 9 – Termovisor Fluke Ti25.



Fonte: <https://www.fluke.com/pt-br/produto/cameras-termicas/ti25>.

Figura 10 – Termovisor Flir C2.



Fonte: <https://flir-technologies.com.br/>.

2.6 Transfer learning

O Transfer Learning é uma técnica que aproveita o conhecimento adquirido por um modelo treinado em um conjunto de dados para melhorar o desempenho em uma tarefa relacionada. Ao utilizar bancos de dados de imagens para orientar o processamento a capacidade de ajustar parâmetros de modelos (como filtros ou classificadores) com base em novos dados ou para otimizar o desempenho em cenários específicos. O treinamento de redes neurais com retropropagação já implica um ajuste adaptativo dos pesos com base nos dados de treinamento.

Para o aprendizado Profundo, o *Transfer Learning* é importante para a segmentação semântica, especialmente em domínios como imagens térmicas, onde grandes *datasets* anotados são escassos ao utilizar uma CNN pré-treinada em um *dataset* massivo de imagens visuais para aprender características genéricas de baixo e médio nível (bordas, texturas, formas).

O ajuste Fino (*Fine-tuning*) adapta as camadas superiores da rede (ou toda a rede) para o *dataset* menor e específico de imagens térmicas, reajustando os pesos para a tarefa de segmentação semântica de anomalias térmicas. Isso economiza tempo e recursos computacionais, e permite que o modelo generalize bem, mesmo com poucos dados anotados.

2.7 Trabalhos relacionados

Logo a seguir, serão abordados os trabalhos relacionados a este estudo.

No artigo *Thermal Fault Detection and Diagnosis of Electrical Equipment Based on the Infrared Image Segmentation Algorithm* (Li, 2021) os autores desenvolvem um modelo que detecta e diagnostica falhas térmicas em equipamentos elétricos. O modelo consiste em um algoritmo de segmentação que opera através da otimização de uma função de energia. Essa função é composta por termos de área e fronteira, que medem qual a probabilidade de pixels pertencerem a uma falha ou ao fundo, e a suavidade da fronteira entre eles. O algoritmo Lazy Snapping é usado para refinar a segmentação, calculando a energia baseado em blocos de pixels. Os parâmetros para o diagnóstico de falhas são definidos por meio de diferenças de temperatura relativa (δ), que ao ultrapassar a margem de 35% é utilizado como limiar para identificar defeitos significativos.

O estudo não define um *dataset* para o aprendizado de máquina, mas valida a metodologia através de sua aplicação em simulações com dados reais. Isso inclui a análise de imagens térmicas de diversos componentes elétricos, como isoladores, cabos, disjuntores e transformadores de corrente.

Para medir a eficácia na segmentação de imagens, o algoritmo usou como métrica a Intersection Over Union (IOU). Além disso foi medido seu desempenho, a velocidade de

execução do algoritmo foi otimizada, especialmente na fase de pré-segmentação, melhorando a sua aplicabilidade em tempo real. Nos estudos de caso, a análise do superaquecimento em um barramento energizado revelou diferenças de temperatura relativa de 68% e 63% entre o ponto de falha e os pontos normais correspondentes, confirmando a capacidade do método em diagnosticar com precisão falhas reais. (Li, 2021)

Para (Lu; Liu; Yuan, 2021) a pesquisa chamada *Thermal Fault Diagnosis of Electrical Equipment in Substations Based on Image Fusion* trata de falhas térmicas em equipamentos elétricos de subestações de distribuição de energia. Este estudo se diferencia dos demais ao fazer a fusão de imagens no espectro visível com imagens térmicas a fim de facilitar a detecção dos objetos e facilitar a identificação de bordas.

O método consiste em um algoritmo de fusão das imagens infravermelhas focando na similaridade da escala de cinza. A detecção de pontos característicos é feita com o operador laplaciano Gaussiano para pontos e o algoritmo de Harris para pontos angulares, em seguida é feita uma transformação da projeção para alinhamento das imagens que por fim é otimizada por um algoritmo genético.

Terminada a fusão, estas imagens vão para o modelo de segmentação e reconhecimento baseado na rede neural convolucional com máscara (Mask R-CNN). O modelo é otimizado combinando otimizadores de gradiente descendente estocástico (SGD) e propagação da raiz do quadrado médio (RMSProp) atualizando os parâmetros da rede, buscando aprimorar a capacidade de segmentação e reconhecimento de regiões anormais. As etapas do diagnóstico de falhas são a aquisição da temperatura mapeando os valores de pixel para temperatura, pré-processamento (suavização, denoising, equalização de histograma), segmentação e fusão da imagem pré-processada em áreas de fundo, temperatura normal e temperatura anormal, cálculo da temperatura média das áreas e diagnosticando a falha do dispositivo elétrico com base em critérios de diferença de temperatura de acordo com os tipos de equipamentos.

No *dataset* tratado com as imagens fundidas as imagens além de serem mais claras, possuem mais contraste e brilho, demonstrando com mais facilidade os pontos de interesse na análise. Na etapa seguinte, o treinamento e testes do modelo mask R-CNN foi dividido na proporção 70/20/10 resultando em 140 imagens de treino e 40 de teste e 20 para verificação vindas em parte em coleta direta e outras obtidas da internet. Durante o teste, o modelo convergiu após 200.000 interações. A métrica utilizada foi *Intersection over Union* (IOU) demonstrando uma precisão média de 93,24%. Os resultados específicos alcançaram os seguintes valores, isoladores de suspensão 79% invólucro isolante de alta tensão de 380kV 74,3% e isolador de suporte de banco de capacitores de 3kV (42%). (Lu; Liu; Yuan, 2021).

Para (Tang; Jian, 2024) no trabalho intitulado *Thermal Fault Diagnosis of Complex Electrical Equipment Based on Infrared Image Recognition* o modelo consiste em três

etapas, que são reduzir o ruído, detectar os equipamentos de interesse e combinar as etapas anteriores para a identificação dos defeitos e classifica-los pela sua severidade baseados em métodos tradicionais de termografia.

Na redução de ruído foi aplicado um algoritmo de DeDn-CNN aprimorado com um módulo de convolução deformável. Esta etapa permite que a rede aprenda padrões complexos de ruído adaptando os pontos de amostragem. No aprimoramento, foi utilizado o algoritmo Ani-SSR (*Anisotropic Single-Scale retinex*) em conjunto com filtragem guiada ponderada (WGF), substituindo a filtragem gaussiana por difusão anisotrópica para preservar detalhes de borda e evitar halos.

Na sequência, a detecção de equipamentos é feita pelo algoritmo retinaNet aprimorado para identificar segmentos rotacionados aumentando a precisão do modelo. Em adicional, o módulo de atenção foi integrado para identificar características importantes em fundos complexos e uma rede de agregação de caminho (PAN) foi adicionada para otimizar a fusão de características com o objetivo de melhorar as informações de textura e posição.

Por último, é feito o diagnóstico de falhas combinando os resultados da detecção com a segmentação semântica usando o DeepLabV3+ onde é verificada a diferença da temperatura relativa. O modelo se mostrou capaz de identificar defeitos em componentes da rede de distribuição elétrica tais como tampas de buchas, elos de desconexão e buchas de transformadores. O cálculo da temperatura relativa foi obtido pela diferença das temperaturas máximas e mínimas do objetos identificados que combinados ao ponto quente e critérios técnicos da termografia possibilitaram classificar as falhas em: geral, grave, crítica ou situação normal.

O *dataset* utilizado consistiu em 508 imagens com resolução de 320x240 pixels de equipamentos elétricos coletadas em subestações no noroeste da China. Dentre elas, 457 foram usadas para treinamento e 51 para teste no denoising e para o diagnóstico de falhas 282 imagens foram selecionadas incluindo 143 imagens com falhas em buchas, elos de desconexão e transformadores de potencial.

As métricas alcançadas em relação à detecção de componentes específicos foram de 87.23% para tampas, 86.54% para elos de desconexão e 90.91% para buchas de transformadores, com baixas taxas de falso positivo de 7.50%, 8.20% e 7.89%, respectivamente. (Tang; Jian, 2024).

Para (Liu *et al.*, 2024) em *Optimized OTSU Segmentation Algorithm-Based Temperature Feature Extraction Method for Infrared Images of Electrical Equipment* o artigo trata da dificuldade imposta em trabalhar com imagens em escala de cinza onde os detalhes da imagens são perdidos, dificultando a segmentação. a proposta é fundir imagens em cor visível com imagens térmicas para que os detalhes de contorno dentre outros sejam

mantidos a fim de melhorar a segmentação. Também é abordado a melhoria de desempenho em relação a velocidade de processamento.

A primeira fase trata da aceleração da segmentação de imagens através de um algoritmo OTSU que integra o algoritmo de Otimização do Lobo Cinzento (GWO). O GWO otimiza o processo de determinação do limiar do OTSU, utilizando a função de variância entre classes do OTSU como critério de parametrização do modelo. Isso permite que o GWO encontre o limiar ótimo de forma eficiente, reduzindo a complexidade computacional e agilizando a binarização da imagem, separando a região do alvo.

A segunda fase do método extrai os valores de temperatura. Como não há uma relação linear da entre a escala de cinza e a temperatura, usa-se o algoritmo K-Nearest Neighbor (KNN) treinado com os dados da barra de cores presente nas imagens infravermelhas fornecendo pontos de correspondência conhecidos entre valores de escala de cinza e suas temperaturas. Após o treinamento o algoritmo KNN é utilizado para prever a temperatura de cada pixel segmentado permitindo obter um vetor de características de temperatura incluindo a temperatura máxima, mínima e média do equipamento medido.

Para os resultados da etapa de segmentação, o algoritmo GWO-OTSU reduziu o tempo médio de cálculo em 83,99% em comparação com o algoritmo OTSU tradicional. Em relação à extração de temperatura, o método baseado em KNN obteve 78,95% no valor absoluto residual médio (Liu *et al.*, 2024).

Em *Autonomous Analysis of Infrared Images for Condition Diagnosis of HV Cable Accessories* de (Mu *et al.*, 2021) o método aplica duas técnicas para a detecção de defeitos em cabos de alta tensão, a rede neural convolucional Faster RCNN e o algoritmo de agrupamento Mean-Shift. Inicialmente é feita a identificação e localização dos objetos a serem medidos nas imagens térmicas, isso inclui terminações de cabos e caixas de aterramento. A rede Faster RCNN é treinada utilizando uma CNN (VGG16) para extrair as características e uma Rede de Proposta de Regiões (RPN) para sugerir as áreas de interesse, e uma camada de RoI Pooling para regularizar os vetores de características, juntando tudo em uma camada de detecção que classifica e refina as caixas delimitadoras do modelo sobre os acessórios. Este processo isola os objeto de interesse.

Na sequência, o algoritmo Mean-Shift é usado para a extração das regiões de aquecimento suspeitas dos objetos medidos. As imagens são convertidas para escala de cinza e o Mean-Shift segmenta os pixels com base nos valores de escala. Após a segmentação das regiões de aquecimento, o método compara a imagem segmentada com regiões de referência (áreas em condição normal). Para terminações de cabo, as regiões de referência são localizadas através de informações de posição da área aquecida e das terminações próximas.

Finalmente, o diagnóstico de condição é definido baseado nos parâmetros de

temperatura calculados: o aumento de temperatura, diferença de temperatura e a diferença de temperatura relativa. Esses parâmetros são comparados com critérios de diagnóstico predefinidos, classificando assim o defeito como "Normal", "Defeito Geral", "Defeito Maior" ou "Defeito Urgente".

O *dataset* utilizado para treinamento e teste da metodologia possui em 100 imagens infravermelhas de acessórios de cabos de AT, coletadas durante inspeções de rotina com uma câmera termográfica FLIR T630 com resolução de 640x480 e emissividade de 0.9. O conjunto está dividido em 50 imagens de terminações de cabo e 50 de caixas de aterramento.

A Faster RCNN foi capaz de identificar os objetos de interesse separando-o do fundo e o Mean-Shift segmentou os pontos de aquecimento como previsto. Os resultados quantitativos, detalhados na Figura 11 da Tabela de resultados do artigo detalham todos os resultados obtidos. (Mu *et al.*, 2021).

Figura 11 – Imagem com os resultados publicados pelos autores do artigo.

Table 4. Testing results of inspection images.

Cable Accessories	Actual Condition		Autonomous Diagnosis Results	
Cable terminations	Normal	32	Normal	32
	General defect	2	General defect	2
	Major defect	7	Major defect	7
	Urgent defect	9	Urgent defect	9
Grounding boxes	Normal	40	Normal	39
	General defect	7	General defect	8
	Major defect	1	Major defect	1
	Urgent defect	2	Urgent defect	2

Fonte: (Mu *et al.*, 2021).

Por fim, em *Infrared Image Segmentation Based on Multi-Information Fused Fuzzy Clustering Method for Electrical Equipment* o modelo organiza dados em grupos flexíveis, combinando os diferentes tipos de informação em um processo com várias etapas interconectadas. Para lidar com os problemas de sensibilidade durante a inicialização do agrupamento e o baixo contraste é feita uma detecção saliência. Gerando assim um mapa de saliência que aprimora o contraste da imagem original, esse mapa é utilizado para determinar os centros de agrupamento iniciais otimizando a convergência. Logo após, o modelo C-means (FCM) é melhorado e restrições espaciais são inseridas na função para reduzir o ruído, melhorando a eficiência computacional ao trabalhar com níveis de cinza em vez de pixels. Em seguida, restrições globais com um fator de peso em função da distância dos pixels em relação ao centro do objeto são incorporadas para reduzir a interferência do fundo. Para ajustar a segmentação um campo conjunto é construído, combinando o campo de agrupamento difuso e um campo aleatório de Markov (MRF). Para isso, um fator de peso adaptativo equilibra os campos, levando à segmentação por pelo critério de máxima probabilidade.

O modelo é aplicado em um *dataset* composto por 150 imagens infravermelhas de equipamentos elétricos de subestações para a transmissão de energia. O desempenho foi quantificado usando métricas como Precisão, Recall e T-measure e tempo de execução.

O algoritmo foi testado segundo as métricas de precisão média e revocação média. O desempenho método teve um tempo médio de execução de 2.56 segundos com pouca sensibilidade ao tamanho da imagem (Qi *et al.*, 2020).

A Tabela 1 relaciona os trabalhos relativos a este estudo.

Tabela 1 – Publicações de referência

ID	Autor(es)	Algoritmo(s) Utilizado(s)	Conjunto de Dados	Métricas Chave
1	Hongzhao Li	Lazy Snapping	Não explicitamente quantificado	Intersection Over Union (IOU)
2	Mingshu Lu et al.	Fusão de Imagem, Mask R-CNN	Conjunto de dados HHU-IR150 (150 imagens IR de equipamentos elétricos).	Intersection Over Union (IOU)
3	Zongbu Tang Xuan Jian	DeDn-CNN, WGF com Ami-SSR, RetinaNet, DeeplabV3+	508 imagens infravermelhas	Acurácia de Reconhecimento em relação Dn-CNN, NL-means ²⁰ , transformada wavelet ²¹ e Lazy Snapping ²²
4	Xueli Liu et al.	Segmentação OTSU otimizada, Extração de temperatura baseada em KNN	20 imagens infravermelhas diferentes de equipamentos de energia.	Comparação direta de desempenho em relação ao processamento do método OTSU tradicional
5	Lixiao Mu et al.	Faster RCNN, Mean-Shift	Imagens infravermelhas de acessórios de cabos de alta tensão; sem tamanho mencionado.	Verificação qualitativa; Tabela 11 fornece contagens de resultados de diagnóstico real vs. automático.
6	Can Qi et al.	Método de Clusterização Fuzzy, campo de Markov restrito	Conjunto de dados HHU-IR150 (150 imagens IR de equipamentos elétricos).	Precisão Média, Revocação Média, Medida T

Fonte: Autor.

3 DESENVOLVIMENTO


Este Capítulo detalha a metodologia adotada para o desenvolvimento da solução proposta. O processo foi segmentado em três fases principais: obtenção e tratamento dos dados, construção e treinamento do modelo de segmentação de imagens, e a aplicação do modelo para análise e classificação de anomalias térmicas.

3.1 Obtenção e tratamento dos dados.

O Projeto se inicia com a construção de um dataset robusto, tal processo se deu ao longo de três meses. Foram coletadas mais de 900 imagens utilizando as câmeras de análise termográfica, Flir C2 e Fluke Ti25, garantindo a captura conjunta das imagens alinhadas no espectro de cor visível (RGB) e infravermelho (térmico). O dataset obtido abrange um conjunto variado de componentes elétricos de automação e controle, dispostos em diversos painéis elétricos industriais, trazendo uma diversidade e representatividade ao conjunto de dados.


Durante a análise exploratória dos dados, foi identificado um desafio crítico à metodologia empregada durante a coleta dos dados: a variabilidade da escala de temperatura das imagens térmicas. Por padrão, as câmeras ajustam sua escala de temperatura dinamicamente (Figura 12) com base nas máximas e mínimas de cada imagem coletada. Foi constatado que a presença indesejada de um componente normalmente quente como um contator ou fonte de alimentação comprime a escala de cores alterando a percepção visual (Figura 13), mascarando anomalias sutis em componentes presentes nas imagens levando a falsos negativos . A seguir é possível visualizar uma destas ocorrências.

Figura 12 – Primeira amostra.



Fonte: Autor.

Figura 13 – Segunda amostra.



Fonte: Autor.

Para superar tal desafio, garantir a consistência dos dados e a possibilidade de comparação das amostras, foi estabelecida uma padronização rigorosa das imagens. Utilizando o software Fluke Smartview, todas as imagens térmicas foram reprocessadas para uma faixa de temperatura fixa e normalizada entre 10°C e 110°C. Esta normalização prévia foi um passo necessário para assegurar a confiabilidade das medições subsequentes.


Neste ponto, apresenta-se o diferencial metodológico deste trabalho: a abordagem para a extração de dados quantitativos da imagem térmica. Em vez de depender de conversões para tons de cinza, cujas fórmulas de luminância podem variar e nem sempre refletem com precisão a percepção de brilho, optou-se por uma metodologia fundamentada na percepção humana. A técnica proposta converte a imagem térmica do espaço de cor padrão (RGB) para o espaço de cor CIELAB.

A vantagem desta abordagem é que o espaço de cor CIELAB foi projetado para ser perceptualmente uniforme, desacoplando a informação de luminância (L^*) da informação de cromaticidade (a^* e b^*). Ao isolar e manipular diretamente o canal L^* , que representa o brilho em uma escala de 0 (preto puro) a 100 (branco puro), estabelece-se uma relação direta entre a intensidade percebida do pixel e a temperatura. Esta técnica não apenas simplifica o processo ao evitar conversões intermediárias, mas também aumenta a robustez do mapeamento para uma escala de temperatura absoluta, constituindo um dos pilares metodológicos deste estudo.

Após a fase de tratamento e o descarte de imagens que não puderam ser padronizadas, o dataset passou a ter aproximadamente 547 pares de imagens. A anotação para o treinamento do modelo de segmentação foi realizada no software *Label Studio*, definindo as classes de interesse como Borne (Figura 14), Disjuntor (Figura 15) e Relé (Figura 16) por meio de caixas delimitadoras. Um algoritmo de conversão foi então desenvolvido para transformar estas anotações em máscaras de segmentação em nível de pixel, salvas no

formato ".npy", prontas para o treinamento da rede neural.

Figura 14 – Objeto de interesse - BORNE.




Fonte: Imagem obtida da internet.

Figura 15 – Objeto de interesse - DISJUNTOR.



Fonte: Imagem obtida da internet.

Figura 16 – Objeto de interesse - RELÉ.



Fonte: Imagem obtida da internet.

3.2 Implementação do Pré-processamento de Imagens

O *pipeline* de desenvolvimento iniciou-se com o tratamento das imagens térmicas brutas. Para garantir que a visualização final fornecesse suporte adequado à decisão humana, conforme discutido nos objetivos, implementou-se computacionalmente o método de conversão *Apparent Greyscale* (Smith *et al.*, 2008).

A escolha deste algoritmo justifica-se pela necessidade de realçar contrastes térmicos sutis que se perdem na conversão padrão. O algoritmo foi codificado em Python utilizando a seguinte formulação baseada no modelo de Nayatani:

$$\hat{L}^* = L^* + [-0.1340 \cdot q(\theta) + 0.0872 \cdot K_{Br}] \cdot s_{uv} \cdot L^* \quad (3.1)$$

Nesta implementação:

- A imagem RGB original foi primeiramente convertida para o espaço CIELUV.
- Calculou-se a saturação (s_{uv}) pixel a pixel para determinar a contribuição cromática.
- O canal resultante \hat{L}^* foi utilizado para gerar a imagem de visualização aprimorada apresentada posteriormente nos resultados, enquanto o canal L^* puro foi utilizado para o treinamento da rede neural, garantindo a linearidade dos dados térmicos.

3.3 Construção do modelo.

Visto que o *dataset* deste estudo conta com um número reduzido de imagens, foi adotado o modelo de segmentação U-Net, pois é uma rede neural convolucional desenvolvida para segmentação eficaz com poucas amostras de treinamento.

Tal aplicação foi executada utilizando a biblioteca TensorFlow e a API Keras.

Como entrada do modelo foram utilizadas imagens de 256 x 256 *pixels* e para melhorar a capacidade do modelo de extrair características relevantes foi utilizado a técnica de *transfer learning* aproveitando a arquitetura *MobileNetV2* pré-treinada no *dataset ImageNet* como *encoder*. As camadas de finais de classificação da *MobileNetV2* foram descartadas para que o *MobileNetV2* pudesse ser acoplado as etapas seguintes, as saídas dos blocos convolucionais em diferentes níveis de profundidade foram preservados para serem utilizados como conexões de atalho, as chamadas *skip connections*.

Normalmente a rede U-Net utiliza em seu *bottleneck* uma camada convolucional na transição entre o *encoder* e o *decoder*, mas durante os ensaios foram inseridas empiricamente duas camadas convolucionais (Conv2D) adicionais com 1024 filtros e função de ativação ReLU, com o objetivo de permitir um processamento mais complexo das características de mais alto nível extraídas pelo *encoder*.

O caminho de expansão é composto por uma sequência de blocos que realizam o *upsampling* das características através de camadas de convolução transposta. Em cada estágio do *decoder*, o mapa de características expandido é concatenado com o mapa de características correspondentes proveniente das *skip connections* do *encoder*, permitindo que o modelo combine informações contextuais (semânticas) com informações de localização (espaciais) para reconstruir a máscara de segmentação com alta precisão.

Na camada de saída, o modelo produz um tensor com quatro canais onde três destes canais representam os componentes de interesse e um para representar o fundo da imagem.

Outra medida para contornar a falta de dados foi a implementação da estratégia de aumento de dados em tempo real (*on-the-fly data augmentation*) diretamente no modelo. Foram aplicadas transformações aleatórias de rotação das imagens nos ângulos de 90, 180 e 270 graus, cor e ajustes aleatórios de brilho e contraste, todos estes exclusivamente nas imagens RGB.

O modelo foi compilado utilizando otimização ADAM, com uma *learning rate* de $0,0001$ para uma convergência estável. A função de perda *SparseCategoricalCrossentropy* foi selecionada, pois, segundo Géron (Géron, 2019), esta função é a mais indicada para problemas de classificação multiclasse, onde os rótulos são representados por números inteiros, como é o caso das máscaras de segmentação geradas neste trabalho. O desempenho é medido pela acurácia por pixel e coeficiente de *Dice* onde foi necessário implementar um fator de suavização para evitar geração de resultados inválidos *NaN* ao realizar possíveis divisões por zero, como aconteceu durante os ensaios do modelo.

O treinamento foi inicialmente configurado para 100 épocas, utilizando um *callback* de *Early Stopping* com paciência de 10 épocas. Isso garantiu que a execução seria interrompida caso o erro de validação parasse de diminuir por 10 épocas consecutivas. Ao fim da execução, o modelo com os melhores ajustes foi salvo no formato HDF5 (.H5).

3.4 Aplicação do modelo

O módulo final do sistema é onde o diferencial metodológico deste trabalho é efetivamente aplicado para à análise quantitativa. O processo se inicia com a interpretação da máscara de segmentação gerada pelo modelo, que delimita as Regiões de Interesse (ROIs).

Conforme a metodologia proposta, a imagem térmica é carregada com a biblioteca *OpenCV* e imediatamente convertida do espaço de cor RGB para CIELAB. O canal de luminância (L^*) é isolado, e seus valores, que no *OpenCV* são representados no intervalo, são mapeados linearmente para a escala de temperatura em graus Celsius, previamente normalizada no *dataset* (10°C a 110°C). Esta abordagem garante que a conversão de brilho

para temperatura seja consistente e imune a variações de paletas de cores, representando uma inovação em relação aos métodos tradicionais de análise termográfica baseada em processamento de imagem. O resultado deste passo é uma matriz de temperaturas na resolução nativa da imagem térmica.

A máscara de segmentação, gerada pelo modelo em baixa resolução (256x256 *pixels*), é então redimensionada para as dimensões exatas da matriz de temperaturas (320x240 *pixels*). Este redimensionamento utiliza a interpolação do vizinho mais próximo para preservar os valores discretos das classes. A máscara é, então utilizada como um filtro para isolar os valores de temperatura pertencentes exclusivamente aos componentes de interesse, descartando todos os demais *pixels* da análise.

A lógica de classificação de defeitos é implementada com base na diferença (ΔT) entre a temperatura máxima encontrada dentro da ROI e a temperatura média do quadro térmico geral, que serve como referência da temperatura ambiente do painel. Com base em limiares técnicos do manual de referência (Infraspection Institute, 2016), o sistema classifica a anomalia em quatro níveis de criticidade, conforme exibido na Tabela 2 do ponto medido em relação a temperatura ambiente.

Tabela 2 – Parâmetros para a definição de defeito e sua criticidade.

Priority	ΔT over ambient air temperature (°C)	Recommended Action
1	$> 40^{\circ}C$	Major discrepancy; repair immediately
2	21 a $40^{\circ}C$	Monitor until corrective measures can be accomplished
3	11 a $20^{\circ}C$	Indicates probable deficiency; repair as time permits
4	1 a $10^{\circ}C$	Possible deficiency; warrants investigation

Fonte:(Infraspection Institute, 2016).

O resultado final será um relatório duplo: um diagnóstico quantitativo com as estatísticas do ROI e sua classificação, e um relatório visual que exhibe a imagem térmica com o contorno da área analisada e um marcador 'X' colorido posicionado no *hotspot*, fornecendo um diagnóstico imediato e de fácil interpretação.

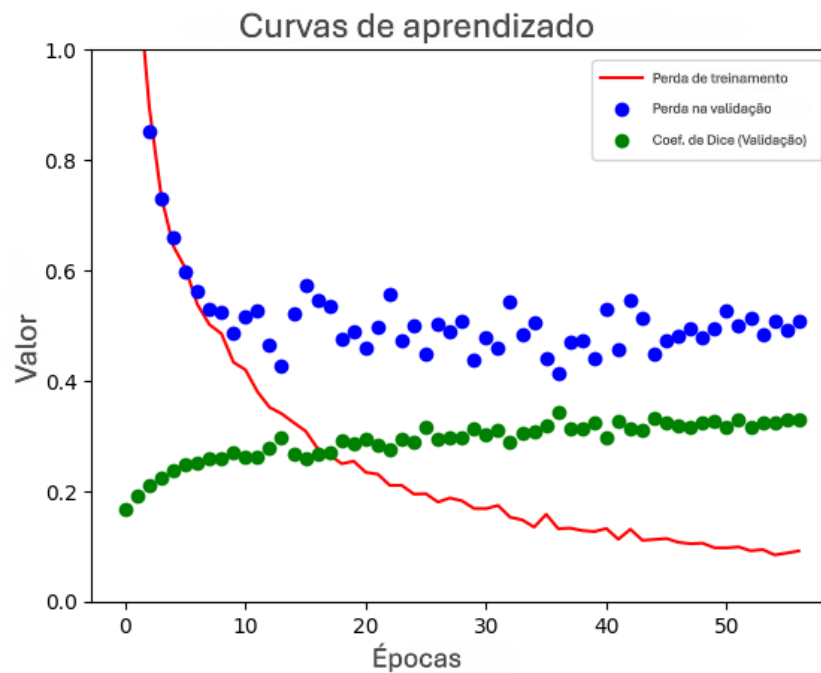
4 RESULTADOS

Este Capítulo apresenta e discute os resultados obtidos após o treinamento do modelo. A análise é dividida em uma avaliação quantitativa, baseada em métricas como o coeficiente *Dice* e a Matriz de Confusão por componente, e uma análise qualitativa, que demonstra a eficácia do sistema na identificação visual de *hotspots* e na classificação automática da severidade térmica em cenários reais.

4.1 Desempenho do modelo de segmentação.

O modelo utilizado usa a estrutura *U-net*, onde as camadas de *Encoding* foram implementadas fazendo uso da técnica de *transfer learning* aproveitando o conhecimento da rede *MobileNet V2* pré-treinada. Durante o treinamento o modelo alcançou a acurácia de 97.18% e um coeficiente de *Dice* de 51.62%. Contudo, na etapa de validação, os resultados foram reduzidos para 85.76% de acurácia e 32.88% para *Dice*. A discrepância entre as métricas de treino e validação evidenciam a presença de *overfitting*, normalmente associado a casos de baixa quantidade de amostras anotadas, principalmente em *datasets* específicos como o de imagens térmicas industriais.

Figura 17 – Métricas de treino e validação do modelo.



Fonte: Autor.

A análise gráfica dos dados de aprendizado ilustram o diagnóstico. É possível ver que o modelo inicia aprendendo as características demonstrado pela redução da função de


perda nos conjuntos de treino e validação. No entanto, a partir da época 14 o cenário muda. A partir deste ponto, a perda da validação tende a subir, indicando que a partir desse ponto o modelo passa a memorizar os dados de treino ao invés de aprender os padrões de generalização. Também pode ser visto que o coeficiente de *Dice* na validação estabiliza em 32%, evidenciando que o modelo atingiu sua máxima capacidade de segmentação com os dados disponíveis.

Embora o coeficiente de *Dice* seja pequeno, principalmente comparado a outras áreas de aplicação como tarefas de segmentação biomédica onde a detecção de borda é crítica. A aplicação na área de termografia preditiva tal desempenho é funcional. O objetivo principal é identificar o objeto de interesse (*ROI*) para que seja extraída a temperatura máxima da região, portanto mesmo que a segmentação seja grosseira nas bordas dos objetos ela é suficiente para isolar o componente defeituoso do fundo frio, permitindo assim a aplicação das regras de classificação de defeitos da norma técnica definida pelo Infrared Institute (Infraspection Institute, 2016).

Mesmo com métricas globais pobres e um coeficiente de Dice mediano, esses valores mascaram o comportamento real do modelo em relação as classes isoladas e sua aplicabilidade. Para demonstrar o quão o sistema é viável, a seção 4.2 decompõe essa análise e avalia do desempenho específico para cada componente.

Figura 18 – Imagem com Componentes segmentados.

Máscara na Imagem Visual



Fonte: Autor.

4.2 Desempenho por componente

A Tabela 3 e a matriz de confusão Figura 19 expõem as métricas por classe da ferramenta de segmentação no conjunto de teste. É possível observar um comportamento diferenciado entre as classes, demonstrando a complexidade visual e geométrica de cada componente registrado.

Tabela 3 – Desempenho Por Componente.

Id	Classe	IoU	Dice	Precisão	Recall
0	Fundo	0.8953	0.9447	0.9344	0.9553
1	Borne	0.4812	0.6497	0.7566	0.5693
2	Disjuntor	0.4671	0.6368	0.5657	0.7284
3	Relé	0.7460	0.8545	0.9026	0.8113

Fonte: Autor.

A classe "Fundo", obteve um resultado elevado (Dice 0,94 e recall 0.95 Tabela 3). Tais dados comprovam que o modelo aprendeu bem a diferenciar os componentes do restante do painel. Através da matriz de confusão também podemos ver a baixíssima porcentagem de casos de falso positivo em relação as demais classes.

Para a classe de interesse "Relés", Figura 16, houve o melhor desempenho com um Dice de 0.85 e precisão de 0.90. O recall de 0.81 indica que poucos relés poderão ter problemas de medição.

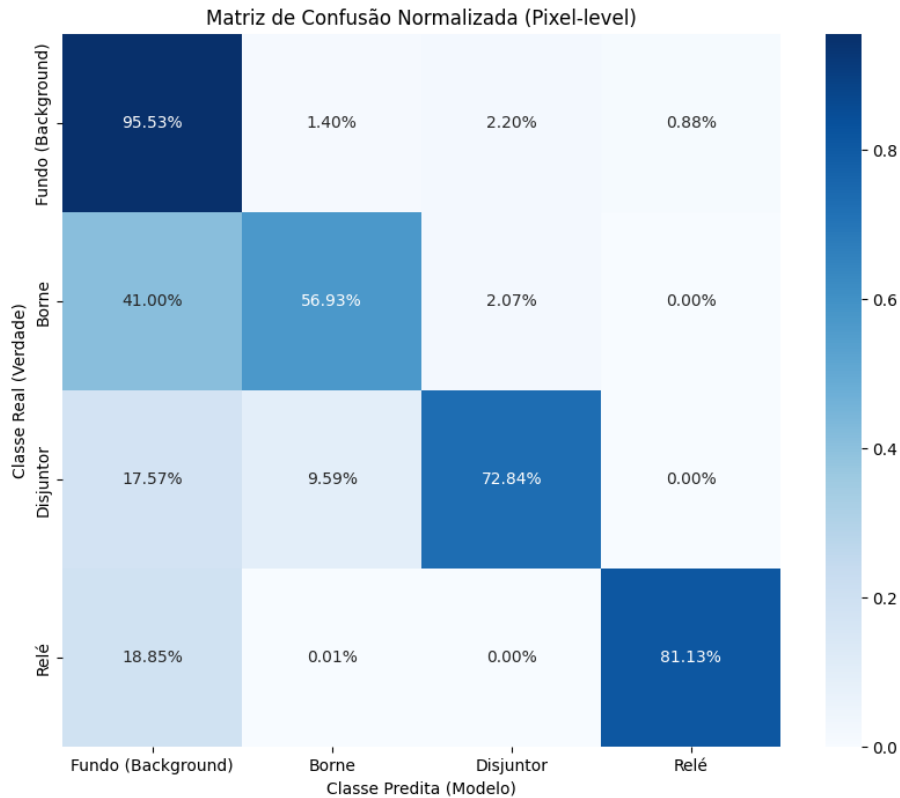
Quanto aos desafios, a classe "Borne", Figura 14 teve uma boa precisão (0.75), mas um baixo Recall (0.56) indicando que uma parte considerável dos bornes pode ficar de fora da análise, transformando esta classe em um ponto de atenção pois, caso o *hotspot* esteja fora da máscara de segmentação poderão ocorrer casos de falso negativo. Nota-se também que a matriz de confusão aponta que em 41% dos casos, um borne pode ser classificado como fundo confirmando a tendencia de que o componente não seja avaliado pelo modelo. Tal situação pode ser justificada devido as dimensões reduzidas do componente (5cm x 0.5cm) e sua disposição em grandes conjuntos, o que dificulta a tarefa de segmentação.

A classe "Disjuntor", Figura 15, de forma oposta, possui um Recall bom (0.72), mas uma precisão baixa (0.56). Neste caso, o modelo é muito abrangente ao definir o que é um disjuntor, incorporando parte dos fios e componentes ao redor justificando a redução da precisão. No caso da classe "Disjuntor" o erro é menos crítico, pois, independentemente da área área ao redor do disjuntor ser considerada, o *hotspot* estará obrigatoriamente dentro da área do disjuntor. Observando este ponto de vista, a maior abrangência por parte do modelo não implica em casos de falsos positivos ou falsos negativos. De certa forma, esse erro do modelo pode ser desejável, garantindo que o disjuntor seja analisado de forma

mais ampla.

Um resultado positivo do modelo é que há uma baixa confusão entre classes. Podemos destacar a taxa nula de confusão entre as classes relés e disjuntores (0%). A matriz também revela que a interação mais significativa entre classes é entre a classe disjuntor, onde 9.59% dos pixels são classificados como borne.

Figura 19 – Matriz de confusão.




Fonte: Autor.

Tendo em vista a complexidade do ambiente industrial e as dimensões do *dataset*, é possível ilustrar uma prova de conceito. O modelo representou bem a classe "Relé" e cobriu de forma adequada a classe "Disjuntor". No entanto, apresenta a necessidade de melhoria para objetos diminutos, como é o caso da classe "Borne". Essa limitação pode ser contornada com a obtenção de mais amostras para aumentar o *dataset*.

4.3 Análise das limitações e casos de falha

Para que ocorra uma melhor compreensão das limitações do modelo, foi realizada uma análise qualitativa de alguns casos onde o coeficiente de Dice foi inferior a 50%. As figuras 20, 21 e 22 demonstram os casos mais críticos encontrados pela rede neural.

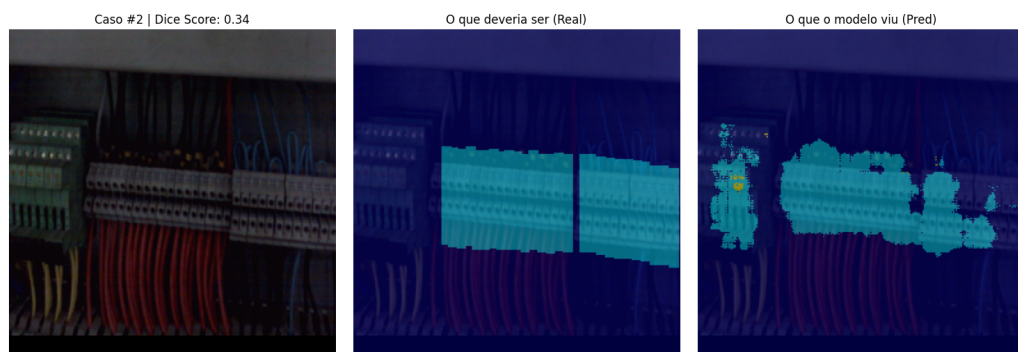
Figura 20 – Irregularidades na detecção de bordas.



Fonte: Autor.

Na Figura 20 é possível ver que o modelo encontrou a classe de acordo com a máscara de referência, porém, a máscara resultante apresenta uma borda irregular. Tal situação indica que a rede aprendeu a identificar o componente, mas não consegue delimitar com exatidão suas bordas. Apesar da situação encontrada, o fato de o ponto de aquecimento vir majoritariamente do centro do objeto valida a medição.


Figura 21 – Sensibilidade à iluminação.



Fonte: Autor.

O caso observado na Figura 21 a baixa iluminação da amostra causa uma detecção errônea, onde outro componente fora do escopo deste trabalho é classificado como um borne. Situações como essa viabilizam casos de falso positivo, impactando a operacionalidade do Diagnóstico Térmico Automatizado 4.4.

Figura 22 – Alucinação.



Fonte: Autor.

Por fim, a Figura 22 exibe um caso de falso positivo significativo (alucinação). A rede neural identificou uma parte da canaleta de cabos como um disjuntor. Isso provavelmente se deve a textura da lateral da calha que, devido as linhas horizontais e coloração preta, sugere partes específicas do disjuntor, Figura 15, como a alavanca de acionamento localizada no centro da peça.

4.4 Diagnóstico Térmico Automatizado

A etapa de diagnóstico automatizado representa a consolidação do processamento de imagem em informações úteis para a manutenção. Inicialmente, obtém-se a temperatura ambiente calculando a temperatura média de toda a imagem. Em seguida, realiza-se a inferência da rede *U-Net* resultando na máscara de segmentação que atua como um filtro espacial sobre a matriz de temperaturas previamente obtidas por meio da conversão do canal L^* do espaço CIELAB.


O algoritmo percorre a Região de Interesse (ROI) delimitada pela máscara e identifica o pixel de temperatura máxima (T_{max}). No exemplo ilustrado na Figura 23a, o sistema detectou uma temperatura máxima de **91,18°C**.

Automaticamente, o software calcula o diferencial de temperatura (ΔT) em relação à referência ambiente e aplica as regras de severidade definidas na Tabela 2 (norma do *Infraspection Institute*). Como resultado, a anomalia foi classificada como **“Defeito Nível 3 (Crítico)”**.

Para facilitar a intervenção da equipe técnica, o sistema gera uma saída visual: um marcador (“X” vermelho) é plotado exatamente sobre o *hotspot* (ponto de maior calor dentro do componente), e uma etiqueta de texto exibe a classificação, a temperatura média e a temperatura máxima. Isso elimina a necessidade de interpretação subjetiva da paleta de cores pelo operador, apresentando um diagnóstico direto e padronizado.

Figura 23 – Respostas do sistema ao analisar algumas amostras.

(a) Amostra 1 - defeito nível 3.



(b) Amostra 2 - Defeito nível 3



(c) Amostra 3 - Defeito nível 2



Fonte: Autor.

4.5 Qualidade da Visualização e Suporte à Decisão Humana

Embora o diagnóstico automatizado visto na Seção 4.4 forneça a classificação técnica do defeito, a validação humana permanece uma etapa de segurança indispensável na manutenção elétrica. Um dos maiores desafios identificados durante a análise exploratória foi a compressão da escala dinâmica nas imagens térmicas convencionais. A presença de um ponto muito quente ("*hotspot*") tende a ofuscar os componentes ao redor mais frios, transformando-os em um fundo escuro e sem detalhes.

Para mitigar esse problema e fornecer contexto visual ao especialista, o sistema implementou a técnica de visualização fundamentada nos princípios da percepção humana (semelhante ao método *Apparent Grayscale* de (Smith *et al.*, 2008)), utilizando o isolamento do canal de luminância do espaço de cor CIELAB na imagem térmica.


A Figura 24 apresenta um comparativo visual dos resultados. Enquanto a termografia padrão foca exclusivamente na temperatura, perdendo a noção de profundidade e textura, a visualização proposta realça as bordas e a estrutura dos componentes.

Observa-se na imagem processada que é possível distinguir claramente os cabos de conexão e limites físicos dos bornes de conexão, elementos que estavam difíceis de visualizar na renderização puramente térmica.


Este resultado demonstra que a abordagem dupla, utilizando o canal L^* para dados de temperatura e o aprimoramento do contraste para visualização, oferece uma visualização melhorada. Isso permite que o manutentor não apenas saiba que "há um defeito", mas identifique visualmente qual conexão específica necessita de reparo, agilizando a ordem de serviço e reduzindo o tempo de exposição ao risco elétrico.

Figura 24 – Comparativo visual: Termografia Padrão vs. Visualização Aprimorada.


(a) Imagem térmica original.



(b) Imagem Termográfica em escala de cinza Padrão.



(c) Escala de cinza com realce de detalhes.



Fonte: Autor.

5 CONCLUSÃO

No Capítulo de encerramento, são sintetizadas as principais conclusões deste estudo, verificando-se o cumprimento dos objetivos propostos. Discute-se o impacto da automação no aumento da segurança operacional e na confiabilidade da manutenção elétrica. Por fim, são elencadas sugestões de melhorias e caminhos para a evolução do sistema em pesquisas futuras.

O presente trabalho atingiu seu objetivo principal ao desenvolver e validar um sistema automatizado para a segmentação e análise de anomalias térmicas em painéis elétricos industriais. A implementação da arquitetura *U-Net*, melhorada pela técnica de *Transfer Learning* com a rede *MobileNetV2*, provou-se viável para o aprendizado das características estruturais de componentes críticos, como bornes, disjuntores e relés, validando a hipótese de que é possível automatizar a triagem de falhas mesmo em cenários com restrição de dados anotados.

Uma contribuição metodológica central deste estudo está na utilização de uma abordagem de pré-processamento baseada no espaço de cor CIELAB. Diferentemente das abordagens convencionais, que dependem de conversões para tons de cinza, muitas vezes sujeitas à perda de informação térmica devido a paletas de cores proprietárias, o isolamento do canal de luminância (L^*) permitiu um mapeamento linear da temperatura (10°C a 110°C). Esta abordagem reduz a subjetividade na interpretação visual, garantindo que a análise computacional seja baseada na intensidade de radiação térmica, alinhando-se aos princípios físicos da termografia. Também foi possível garantir que essa estratégia classifique a severidade da falha de forma confiável em relação à condição física real do equipamento, permitindo a aplicação automatizada dos critérios normativos do *Infraspection Institute*.

Em relação ao desempenho do modelo treinado, a análise dos resultados individualizada mostra um comportamento distinto entre classes. O sistema demonstrou alta capacidade de segmentação de componentes com formas geométricas bem definidas, como relés (Dice de 85%) e disjuntores, validando a capacidade de aprender padrões semânticos complexos. Em contrapartida, há uma limitação na detecção de componentes de pequenas dimensões e fortemente aglomerados, como bornes, há também alta sensibilidade a variação de iluminação. Esses fatores demonstram que a escassez de dados de treino restringe a capacidade de generalização do modelo, ressaltando a necessidade de expansão do *dataset* para outros cenários.

Apesar das limitações na delimitação das bordas em componentes menores, a aplicação do diagnóstico mostrou-se funcional e robusto para aplicação em manutenção preditiva. o sistema foi capaz de localizar as regiões de interesse (ROI) e identificar os

pontos de aquecimento críticos (*hotspots*), aplicando devidamente os critérios da norma do *Infrared Institute* para a classificação de falhas. A entrega de um diagnóstico padronizado, visual e textual avança na segurança operacional, reduzindo a exposição aos riscos impostos a profissionais do setor elétrico.

Concluindo, o sistema proposto oferece uma base sólida para a automação de análise de imagens termográficas, transformando uma análise visual em um processo padronizado. Para trabalhos futuros, sugere-se fortemente a expansão da base de imagens anotadas para corrigir o *Overfitting* e melhorar a generalização das bordas segmentadas. Recomenda-se também a exploração de arquiteturas de segmentação semântica alternativas, como a *DeepLabV3+*. Por fim, recomenda-se a expansão do *range* de temperatura a fim de detectar uma maior quantidade de situações de falha.

REFERÊNCIAS

- CHEN, L.-C. *et al.* **Rethinking Atrous Convolution for Semantic Image Segmentation**. arXiv, 2017. Version Number: 3. Disponível em: <https://arxiv.org/abs/1706.05587>.
- FLIR Systems, Inc. **5 Factors Influencing Radiometric Temperature Measurements**. Wilsonville, OR 97070, 2016. 12 p. White Paper. Disponível em: <https://www.flir.com/oem/>.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. [S.l.: s.n.]: O'Reilly Media, 2019.
- GONZALES, R. C. **Processamento digital de imagens**. [S.l.: s.n.]: Pearson, 2013. ISBN 978-85-8143-586-2.
- INFRASPECTION INSTITUTE. **Standard for Infrared Inspection of Electrical Systems & Rotating Equipment**. Burlington, NJ, 2016. 2016 Edition.
- LI, H. Thermal Fault Detection and Diagnosis of Electrical Equipment Based on the Infrared Image Segmentation Algorithm. **Advances in Multimedia**, v. 2021, p. 1–7, nov. 2021. ISSN 1687-5699, 1687-5680. Publisher: Wiley. Disponível em: <https://www.hindawi.com/journals/am/2021/9295771/>.
- LIU, X. *et al.* Optimized OTSU Segmentation Algorithm-Based Temperature Feature Extraction Method for Infrared Images of Electrical Equipment. **Sensors**, v. 24, n. 4, p. 1126, fev. 2024. ISSN 1424-8220. Publisher: MDPI AG. Disponível em: <https://www.mdpi.com/1424-8220/24/4/1126>.
- LU, M.; LIU, H.; YUAN, X. Thermal Fault Diagnosis of Electrical Equipment in Substations Based on Image Fusion. **Traitement du Signal**, v. 38, n. 4, p. 1095–1102, ago. 2021. ISSN 0765-0019, 1958-5608. Publisher: International Information and Engineering Technology Association. Disponível em: <https://www.iieta.org/journals/ts/paper/10.18280/ts.380420>.
- MU, L. *et al.* Autonomous Analysis of Infrared Images for Condition Diagnosis of HV Cable Accessories. **Energies**, v. 14, n. 14, p. 4316, jul. 2021. ISSN 1996-1073. Publisher: MDPI AG. Disponível em: <https://www.mdpi.com/1996-1073/14/14/4316>.
- NAYATANI, Y. Simple estimation methods for the helmholtz—kohlrausch effect. **Color Research & Application**, Wiley Online Library, v. 22, n. 6, p. 385–401, 1997.
- QI, C. *et al.* Infrared image segmentation based on multi-information fused fuzzy clustering method for electrical equipment. **International Journal of Advanced Robotic Systems**, v. 17, n. 2, p. 172988142090960, mar. 2020. ISSN 1729-8814, 1729-8814. Publisher: SAGE Publications. Disponível em: <http://journals.sagepub.com/doi/10.1177/1729881420909600>.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-Net: Convolutional Networks for Biomedical Image Segmentation**. arXiv, 2015. Version Number: 1. Disponível em: <https://arxiv.org/abs/1505.04597>.

SMITH, K. *et al.* Apparent greyscale: A simple and fast conversion to perceptually accurate images and video. **Computer Graphics Forum**, v. 27, n. 2, p. 193–200, 2008.

TANG, Z.; JIAN, X. Thermal fault diagnosis of complex electrical equipment based on infrared image recognition. **Scientific Reports**, v. 14, n. 1, mar. 2024. ISSN 2045-2322. Publisher: Springer Science and Business Media LLC. Disponível em: <https://www.nature.com/articles/s41598-024-56142-x>.