

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL

DIULHIO CANDIDO DE OLIVEIRA

DETECÇÃO E SEGMENTAÇÃO DE MODIFICAÇÕES EM PLACAS DE
CIRCUITO IMPRESSO EM AMBIENTES NÃO CONTROLADOS
ATRAVÉS DE MÉTODOS DE UMA CLASSE E AUTOENCODERS

TESE

CURITIBA

2023

DIULHIO CANDIDO DE OLIVEIRA

**DETECÇÃO E SEGMENTAÇÃO DE MODIFICAÇÕES EM
PLACAS DE CIRCUITO IMPRESSO EM AMBIENTES NÃO
CONTROLADOS ATRAVÉS DE MÉTODOS DE UMA CLASSE E
AUTOENCODERS**

**Detection and segmentation of modifications in printed circuit boards
in uncontrolled environments using one-class methods and
Autoencoders**

Tese apresentado como requisito para obtenção do título de Doutor em Engenharia Elétrica e Informática Industrial, do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Marco Aurelio Wehrmeister

Coorientador: Prof. Dr. Bogdan Tomoyuki Nassu

CURITIBA

2023



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es).

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



DIULHIO CANDIDO DE OLIVEIRA

DETECÇÃO E SEGMENTAÇÃO DE MODIFICAÇÕES EM PLACAS DE CIRCUITO IMPRESSO EM AMBIENTES NÃO CONTROLADOS ATRAVÉS DE MÉTODOS DE UMA CLASSE E AUTOENCODERS

Trabalho de pesquisa de doutorado apresentado como requisito para obtenção do título de Doutor Em Ciências da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia De Computação.

Data de aprovação: 05 de Outubro de 2023

Dr. Marco Aurelio Wehrmeister, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Alceu De Souza Britto Junior, Doutorado - Pontifícia Universidade Católica do Paraná (Pucpr)

Dr. Andre Eugenio Lazzaretti, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Eduardo Todt, Doutorado - Universidade Federal do Paraná (Ufpr)

Dr. Joao Alberto Fabro, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Rodrigo Minetto, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 06/12/2023.

À minha família e amigos, que sempre
apoiaram e deram forças.

AGRADECIMENTOS

Este trabalho não poderia ser terminado sem a ajuda de diversas pessoas e/ou instituições às quais presto minha homenagem. Certamente esses parágrafos não irão atender a todas as pessoas que fizeram parte dessa importante fase de minha vida. Portanto, desde já peço desculpas àquelas que não estão presentes entre estas palavras, mas elas podem estar certas que fazem parte do meu pensamento e de minha gratidão.

Aos professores Marco Aurelio e Bogdan, pelos desafios propostos, conselhos, motivação e vários momentos dedicados a produção deste trabalho.

A minha esposa Fabiane, o amor da minha vida, que sempre me apoiou e cobrou, sempre acreditando em mim e me tornando uma pessoa melhor a cada dia.

A minha mãe Jandira e meu padrasto Marcelo, que lutaram para me dar o melhor que estivesse em seu alcance. Além de me mostrar sempre que todo o estudo vale a pena e podemos chegar longe.

A toda a minha família, pelos ótimos momentos de lazer e viagens em feriados e férias que dão aquela recarregada nas "baterias".

Aos amigos Ariana e Hagner, pelos ótimos momentos em churrascos e jantares, porque nem só de trabalho vive o homem.

A todos os professores que tive contato ao longo da vida, com certeza cada um teve uma pequena participação na minha formação e conclusão deste trabalho.

A UTFPR e CPGEI por disponibilizar a estrutura necessária para realização desta tese.

Enfim, a todos os que de alguma forma contribuíram para a realização deste trabalho, obrigado!

A jornada pelo conhecimento: Em busca da harmonia entre a inteligência humana e a inteligência artificial, para alcançar a excelência no mundo tecnológico e social (ChatGPT, 2023).

RESUMO

DE OLIVEIRA, Diulhio Candido. **Detecção e segmentação de modificações em placas de circuito impresso em ambientes não controlados através de métodos de uma classe e Autoencoders**. 2023. 96 f. Tese (Doutorado em Engenharia Elétrica e Informática Industrial) – Universidade Tecnológica Federal do Paraná. Curitiba, 2023.

A inspeção visual de placas de circuito impresso (PCI) é um problema importante em áreas como controle de qualidade em linhas de produção e detecção de fraudes. A inspeção envolve a detecção de erros de montagem e da substituição ou adição de novos componentes não especificados originalmente. Tais mudanças podem interferir no funcionamento correto do circuito, sendo a detecção de adulterações por meio da automação da inspeção visual uma alternativa viável que acelera o processo produtivo e a detecção de fraudes por não especialistas. No entanto, a detecção de anomalias apresenta desafios, especialmente quando há um desequilíbrio entre as classes de dados e poucas amostras de anomalias disponíveis. Além disso, a inspeção visual em ambientes não controlados, como a detecção de anomalias em PCIs, é complexa devido a variações externas, como iluminação, ângulo e perspectiva. Este trabalho propõe uma abordagem baseada em aprendizado profundo, usando *Autoencoders* convolucionais, para a detecção e segmentação de anomalias em imagens de PCIs em ambientes não controlados. O objetivo principal é desenvolver um método que possa operar em condições reais, treinado apenas com imagens sem anomalias. Isso elimina a necessidade de se coletar um grande volume de imagens com anomalias para treinamento, o que pode ser inviável ou custoso. As contribuições deste trabalho incluem a definição de uma função de custo e uma função de comparação eficazes para treinar e avaliar os *Autoencoders* convolucionais. Essas funções permitem a detecção e segmentação de anomalias com base em características de alto nível em vez de *pixels* individuais, tornando o método mais robusto em ambientes não controlados. Além disso, o conjunto de dados rotulado MPI-PCB foi criado, contendo imagens de PCIs para treinamento, avaliação e teste do método proposto. Este conjunto de dados foi disponibilizado publicamente, juntamente com máscaras de anomalias para comparação com outros métodos. Os experimentos de validação do método foram realizados sobre os métodos da literatura PaDiM, SPADE, DFR e SPTM, utilizando a base de imagens proposta. O método proposto alcançou os melhores resultados em todas as regiões analisadas da imagem, obtendo Intersection over Union de 0,677 contra 0,507 do melhor método comparado, o PaDiM. Além disso, foram realizados experimentos na base de imagens para detecção de anomalias MVTEC-AD, mostrando a eficácia do método em outras aplicações. No geral, este trabalho oferece uma solução robusta para o problema descrito e contribuiu para o objetivo de desenvolver métodos capazes de detectar anomalias em ambientes não-controlados.

Palavras-chave: detecção de anomalias. segmentação de anomalias. PCI. inspeção visual. aprendizado profundo.

ABSTRACT

DE OLIVEIRA, Diulhio Candido. **Detection and segmentation of modifications in printed circuit boards in uncontrolled environments using one-class methods and Autoencoders.** 2023. 96 p. Thesis (PhD in Electrical and Computer Engineering) – Universidade Tecnológica Federal do Paraná. Curitiba, 2023.

The visual inspection of printed circuit boards (PCBs) is an important problem in areas such as quality control in production lines and fraud detection. Inspection involves detecting assembly errors and identifying the replacement or addition of new components that were not originally specified. Such changes can interfere with the correct behavior of the circuit. Detecting alterations through automated visual inspection is a viable alternative that accelerates the production process or the detection of fraud by non-specialists. However, anomaly detection presents challenges, especially when there is an imbalance between data classes and few anomaly samples available. Additionally, visual inspection in uncontrolled environments, such as anomaly detection in PCBs, is complex due to external variations, such as lighting, angle, and perspective. This work proposes a deep learning-based approach using convolutional autoencoders for the detection and segmentation of anomalies in PCB images in uncontrolled environments. The main objective is to develop a method that can operate in real conditions, trained only with images without anomalies. This eliminates the need to collect a large volume of images with anomalies for training, which can be impractical or costly. The contributions of this work include defining an effective cost function and comparison function for training and evaluating convolutional autoencoders. These functions enable the detection and segmentation of anomalies based on high-level features rather than individual pixels, making the method more robust in uncontrolled environments. Additionally, the labeled dataset MPI-PCB was created, containing PCB images for training, evaluation, and testing of the proposed method. This dataset was made publicly available, along with anomaly masks for comparison with other methods. Validation experiments of the method were performed against comparative methods from the literature PaDiM, SPADE, DFR and SPTM, using the proposed image dataset. The proposed method achieved the best results in all analyzed regions of the image, obtaining an Intersection over Union of 0.677 compared to the best comparative method's 0.507, the PaDiM. Furthermore, experiments were conducted on the MVTec-AD anomaly detection image dataset, demonstrating the method's effectiveness in other applications. Overall, this work provides a robust solution to the described problem and contributes to the goal of developing methods capable of detecting anomalies in uncontrolled environments.

Keywords: anomaly detection. anomaly segmentation. PCB. visual inspection. deep learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Processo de inferência executado por meio de uma técnica baseada na reconstrução, utilizando uma arquitetura de <i>Autoencoder</i> convolucional. Nesse contexto, o <i>Autoencoder</i> é treinado exclusivamente com imagens sem anomalias. Quando uma imagem contendo anomalias é fornecida como entrada, o <i>Autoencoder</i> produz uma saída em que as modificações não são reconstruídas. Posteriormente, por meio de uma função de comparação ou métrica de similaridade, a entrada e a saída são comparadas, permitindo a segmentação das anomalias.	19
Figura 2 – Exemplo de anomalias fora da distribuição. Nesse exemplo, uma Rede Convolucional classificou corretamente a imagem de um Panda, com 57,7% de confiança, ao adicionar um ruído imperceptível para humanos na imagem, a mesma rede passou a classificar a imagem como “Gibão” (uma espécie de primata) com 99,3% de confiança.	25
Figura 3 – Exemplos das bases (a) MNIST e (b) CIFAR-10.	28
Figura 4 – Método multi-escala proposto por Defard <i>et al.</i> (2021), onde o vetor de características é extraído por uma rede neural profunda, e o método de estimativa de similaridade utiliza informações da distribuição Gaussiana dos dados.	34
Figura 5 – Exemplos de Placas de Circuito Impressos (PCIs) sem e com montagem. O que diferencia os dois tipos é a solda ou montagem dos componentes.	35
Figura 6 – Imagem da PCI destacando as anomalias contidas na base de imagens. Algumas são de fácil identificação, enquanto outras requerem uma maior atenção e experiência para serem identificadas. As modificações consistem na adição de pequenos circuito integrados e fios <i>jumpers</i>	42
Figura 7 – Imagem da PCI e sua respectiva máscara para a comparação de métodos de segmentação de anomalias.	43
Figura 8 – Comparação de imagens da base <i>Multi-Perspective and Illumination Printed Circuit Board</i> (MPI-PCB), demonstrando a necessidade do alinhamento.	43
Figura 9 – Comparação da imagem de uma PCI antes e após alinhamento utilizando <i>Scale-Invariant Feature Transform</i> (SIFT) e algoritmo <i>Random Sampling Consensus</i> (RANSAC).	44
Figura 10 – Exemplo de variação de distorções de aparência apresentadas em uma mesma região após o procedimento de alinhamento das imagens.	45
Figura 11 – Particionamento realizado nas imagens das PCIs.	46
Figura 12 – Um exemplo sem anomalias de cada textura presente na base de imagens <i>MVTec Anomaly Detection</i> (MVTec-AD): carpete, grade, couro, azulejo e madeira.	48
Figura 13 – Um exemplo com anomalias de cada textura presente na base de imagens MVTec-AD: carpete, grade, couro, azulejo e madeira.	48
Figura 14 – Um exemplo sem anomalias de cada objeto presente na base de imagens MVTec-AD: garrafa, cabo, cápsula. noz, porca de metal, pílula, parafuso, escova de dentes, transistor e fecho de correr.	48

Figura 15 – Um exemplo com anomalias de cada objeto presente na base de imagens MVTEC-AD: garrafa, cabo, cápsula, noz, porca de metal, pílula, parafuso, escova de dentes, transistor e fecho de correr.	49
Figura 16 – Processo de <i>Cutout</i> gerado durante o treinamento. Os retângulos pretos inseridos na imagem funcionam como uma estratégia de regularização.	52
Figura 17 – Representação da função de custo utilizada no trabalho.	54
Figura 18 – (a) Imagem de entrada de uma PCI com modificações (superior) e sem modificações (inferior), (b) imagem de reconstrução do <i>Autoencoder</i> Convolutivo (AEC), (c) diferença absoluta entre <i>pixels</i> entre a imagem de entrada e a reconstrução, e (d) método proposto para a segmentação de anomalias usando a diferença perceptiva. A diferença absoluta entre <i>pixels</i> tem altos valores mesmo em regiões sem diferenças visuais. Já no método proposto as regiões caracterizadas por anomalias são claras e bem definidas.	55
Figura 19 – Diagrama de funcionamento das etapas de geração do mapa de anomalias do método proposto.	56
Figura 20 – Comparação da segmentação de anomalias do método proposto e os métodos comparativos, as imagens das regiões 3×2 , 2×3 e 2×2 contêm PCIs contendo modificações, enquanto as imagens das regiões 2×2 and 4×3 contêm PCIs sem modificações. Os contornos vermelhos representam as anomalias detectadas pelos algoritmos ou métodos avaliados.	69
Figura 21 – Curvas <i>Receiver Operator Characteristic</i> (ROC) de detecção e segmentação usando o método proposto para todas as texturas e objetos da base de imagens MVTEC-AD. As linhas contínuas representam dados da categoria objetos, enquanto as linhas pontilhadas representam dados da categoria de texturas.	71
Figura 22 – Exemplos dos objetos Cápsula e Pílula da base MVTEC-AD, onde o objeto da primeira imagem é livre de anomalia, e os outros são exemplos de anomalias variadas contidas na base de imagens.	74
Figura 23 – Resultados de reconstrução para diferentes regiões da placa na base de imagens MPI-PCB, e objetos e texturas da base MVTEC-AD. Nesses experimentos os pesos λ_1 e λ_2 da função de custo foram variados entre 0 e 1, conforme a Equação 7.	76
Gráfico 1 – Taxa de aprendizado usada durante o treinamento com otimizador Adam.	64
Gráfico 2 – Curvas ROC para a detecção de anomalias de cada uma das regiões avaliadas. O número das regiões indica a coluna e linha que representa cada região na imagem particionada (ver Figura 11).	66
Gráfico 3 – Curvas ROC para a segmentação de anomalias de cada uma das regiões avaliadas. O número das regiões indica a coluna e linha que representa cada região na imagem particionada (ver Figura 11).	67

LISTA DE TABELAS

Tabela 1 –	Números da base de imagens MVTEC-AD, sendo o número de imagens para as etapas de treinamento e teste, além do número de defeitos por categoria e a respectiva dimensão das imagens.	47
Tabela 2 –	A arquitetura utilizada para o <i>Autoencoder</i> Convolutacional. Todas as camadas de convolução ou convolução transposta usam tamanho de filtros 5×5 , passo 2×2 e preenchimento 0.	50
Tabela 3 –	Probabilidades e faixas de valores utilizados para o aumento de dados <i>online</i>	64
Tabela 4 –	Resultados do método proposto e dos métodos comparativos para a base de imagens MPI-PCB. Os resultados são mostrados apenas nas regiões que contêm ao menos uma modificação no conjunto de testes. Os números das regiões representam as colunas e linhas da imagem particionada (para mais detalhes ver a Figura 11). Valores maiores indicam os melhores desempenhos, sendo que para precisão, <i>recall</i> e <i>F-score</i> os resultados são para o limiar que apresentou maior <i>G-mean</i>	65
Tabela 5 –	Resultados obtidos com a base de imagens MVTEC-AD para o método proposto e os métodos comparativos para a categoria de objetos.	72
Tabela 6 –	Resultados obtidos com a base de imagens MVTEC-AD para o método proposto e os métodos comparativos para as categorias de texturas.	73

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

SIGLAS

AE	<i>Autoencoders</i>
AEC	<i>Autoencoder Convolucional</i>
EQM	Erro Quadrático Médio
FAST	<i>From Accelerated Segment Test</i>
FN	Falso Negativos
FP	Falso Positivos
GAN	<i>Generative Adversarial Network</i>
IoU	<i>Intersection over the Union</i>
k-NN	<i>k vizinhos mais próximos, do inglês k Nearest Neighbors</i>
MPI-PCB	<i>Multi-Perspective and Illumination Printed Circuit Board</i>
PCI	Placas de Circuito Impresso
QP	Questão de Pesquisa
R-CNN	<i>Region Based Convolutional Neural Networks</i>
RANSAC	<i>Random Sampling Consensus</i>
ReLU	Unidade Linear Retificada
ROC	<i>Receiver Operator Characteristic</i>
ROC-AUC	Área abaixo da curva ROC
SIFT	<i>Scale-Invariant Feature Transform</i>
SSD	<i>Single-Shot Detector</i>
SSIM	<i>Structural Similarity Index Measure</i>
SVM	Máquinas de Vetor de Suporte, do inglês <i>Support Vector Machines</i>
TFP	Taxa de Falso Positivos
THT	montagem <i>through-hole</i>
TVP	Taxa de Verdadeiro Positivos
VAE	<i>Variational Autoencoder</i>
VN	Verdadeiro Negativos
VP	Verdadeiro Positivos

ACRÔNIMOS

COCO	<i>Common Objects in Context</i>
MVTec-AD	<i>MVTec Anomaly Detection</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	16
1.2	DEFINIÇÃO DO PROBLEMA	18
1.3	OBJETIVOS GERAIS	19
1.4	QUESTÕES DE PESQUISA	20
1.5	CONTRIBUIÇÕES GERAIS DO MÉTODO	20
1.6	ESTRUTURA DO DOCUMENTO	22
2	ESTADO DA ARTE	23
2.1	MÉTODOS PARA A DETECÇÃO DE ANOMALIAS	24
2.2	APLICAÇÕES DE DETECÇÃO DE ANOMALIAS	27
2.3	TÉCNICAS PARA A DETECÇÃO DE ANOMALIAS	29
2.3.1	Métodos de classificação	29
2.3.2	Reconstrução	31
2.3.3	Similaridade de características	33
2.4	DETECÇÃO DE ANOMALIAS EM PCI	35
2.5	CONSIDERAÇÕES	37
3	MATERIAL E MÉTODOS	39
3.1	DEFINIÇÃO DO PROBLEMA	39
3.2	DEFINIÇÃO MATEMÁTICA	40
3.3	BASE DE IMAGENS MPI-PCB	41
3.3.1	Alinhamento das imagens	42
3.3.2	Particionamento das imagens	45
3.4	BASE DE IMAGENS MVTEC-AD	47
3.5	ARQUITETURA DOS <i>AUTOENCODERS</i>	48
3.6	FUNÇÃO DE CUSTO	52
3.7	SEGMENTAÇÃO DE ANOMALIAS	54
3.8	DISCUSSÃO	57
4	RESULTADOS E DISCUSSÃO	59
4.1	MÉTODOS COMPARATIVOS	59
4.2	MÉTRICAS DE AVALIAÇÃO	60
4.3	SELEÇÃO DO LIMAR DE CLASSIFICAÇÃO	62
4.4	PROCEDIMENTO DE TREINAMENTO	62
4.5	RESULTADOS NA BASE MPI-PCB	65
4.6	RESULTADOS NA BASE DE IMAGENS MVEC-AD	70
4.7	ESTUDOS DE ABLAÇÃO DA FUNÇÃO DE CUSTO	75
4.8	DISCUSSÃO	77
5	CONCLUSÕES E PERSPECTIVAS FUTURAS	79
5.1	QUESTÕES DE PESQUISA	81
5.2	LISTA DE PUBLICAÇÕES	83

REFERÊNCIAS 84

1 INTRODUÇÃO

A inspeção visual de Placas de Circuito Impressos (PCIs) é um problema importante em áreas como controle de qualidade em uma linha de produção (KUMAR, 2008; BERGMANN *et al.*, 2019; COHEN; HOSHEN, 2020) e detecção de fraudes (OLIVEIRA *et al.*, 2017). Essa inspeção inclui a detecção da substituição de componentes eletrônicos, detecção de erros de montagem, e a adição de novos componentes não especificados originalmente. Tais modificações podem interferir no funcionamento correto do circuito, que deve estar de acordo com seu propósito original. Algumas dessas modificações podem gerar comportamentos inesperados que danificam componentes ou a placa na totalidade, requerendo uma manutenção especializada na PCI. Além da inspeção visual, a inspeção de placas de circuito impresso pode ser realizada por testes elétricos. Entretanto, os testes elétricos requerem tempo, conhecimento especializado de eletrônica, e de detalhes do projeto do circuito, os quais nem sempre estão disponíveis. O manuseio indevido das placas pelo especialista também pode causar danos, podendo aumentar ainda mais o tempo de inspeção das placas. Assim, a detecção de adulterações através da automação da inspeção visual pode ser considerada uma alternativa viável que acelera o processo produtivo ou a detecção de fraudes. Embora adulterações sejam pontuais nessa aplicação, também são raras, características que impõem dificuldades em observar instâncias que apresentem todas as variações possíveis. Tais adulterações podem ser chamadas de anomalias.

Anomalias, anormalidades, exceções, falhas, ou novidades são observações que fogem do padrão de uma distribuição de dados, ou seja, uma condição não esperada, que foge do normal. A detecção de anomalias consiste no ato de encontrar as anomalias em um contexto específico, ações que fogem do padrão realizado por um indivíduo, ou até mesmo novidades nunca observadas em um sistema (HAWKINS, 1980). Por outro lado, as observações consideradas no padrão são conhecidas como normais. A detecção destas anomalias está inserida em diversos contextos em que é necessário detectar as disparidades para não haver algum tipo de prejuízo. Exemplos desses sistemas, são: linhas de produção industrial, sistemas de monitoramento por câmeras, a rede de computadores de uma grande empresa ou governo, diagnósticos médicos, entre outros. Muitas dessas aplicações requerem monitoramento constante ou conhecimento complexo do problema. Neste contexto, o aprendizado de máquina se torna uma ferramenta interessante para a detecção de anomalias.

Um dos grandes desafios da detecção de anomalias está em um dos primeiros passos de

um sistema com aprendizado de máquina: a coleta de dados (DUDA *et al.*, 2001). Em muitas aplicações de detecção de anomalias é comum haver um grande desbalanceamento entre as classes (CHANDOLA *et al.*, 2009). Em geral, as bases de dados contêm muitas observações normais, porém nenhuma ou um número reduzido de amostras anormais. Por exemplo, em muitos casos de diagnóstico médico há poucos dados que demonstrem a ocorrência de alguma doença, além de haver uma série de questões éticas para o uso de algumas informações que limitam sua utilização. Também é difícil obter um conjunto de anomalias que seja representativo no universo de possíveis anomalias, ou seja, não necessariamente todas as anomalias coletadas representam tudo o que pode ser considerado anormal em uma aplicação. Além da escassez de dados, podem existir ruídos nos dados normais que podem ser interpretados como anomalias. Conforme a disponibilidade dos dados, um problema de detecção de anomalias usando técnicas de aprendizado de máquina pode ser abordado de três formas diferentes: (i) supervisionada, (ii) semi-supervisionada e (iii) não-supervisionada. As técnicas supervisionadas e semi-supervisionadas são dependentes de conhecimento prévio do problema, dependentes de base de dados com uma ou mais classes rotuladas (ALPAYDIN, 2009). A abordagem não-supervisionada não requer nenhum conhecimento prévio, nessa abordagem parte-se do princípio que as anomalias não se encaixam em nenhum conjunto.

A inspeção de PCIs pode ser feita de forma visual. Para tal, imagens são o formato de dados mais indicado, porém a inspeção visual é problema complexo. Uma imagem pode conter inúmeras características que definem padrões, identificar tais padrões não é trivial e requer técnicas complexas para uma solução satisfatória. As técnicas de Aprendizado Profundo (*Deep Learning*) têm sido amplamente utilizadas, tendo bons resultados em aplicações com imagens (KRIZHEVSKY *et al.*, 2012; SIMONYAN; ZISSERMAN, 2015; SZEGEDY *et al.*, 2015; GOODFELLOW *et al.*, 2014; REDMON *et al.*, 2016). Estas técnicas aprendem os padrões extraíndo as características, tornando o aprendizado mais eficaz. Por outro lado, essas técnicas requerem uma grande quantidade de dados para que os algoritmos não fiquem restritos a soluções sub ótimas, visto que muitos parâmetros devem ser ajustados. Assim, considerando que na detecção de anomalias as amostras de imagens com anomalias são em quantidade bastante reduzida, ou ainda inexistentes, a aplicação deste tipo de técnica pode ser considerado um desafio.

1.1 MOTIVAÇÃO

Uma instância importante da inspeção visual é a detecção de fraudes. Um exemplo de fraude comum em países como Brasil (SLATTERY, 2021) e Índia (CHAKRABORTY, 2017; SRINIVAS, 2020), é a adulteração de PCIs usadas em bombas de combustíveis. No Brasil a modificação de PCIs em bombas de combustível é proibida sem a autorização do órgão regulador, e portanto considerada crime. Tais adulterações interferem no processo de abastecimento dos veículos, onde o volume de combustível abastecido e mostrado ao consumidor é inferior ao colocado no tanque do veículo. Neste caso, é necessário que o agente do órgão fiscalizador remova a PCI da bomba de combustível e a compare com uma imagem de referência ou uma amostra real. Para evitar ações legais dos estabelecimentos que deixam de arrecadar durante o processo de inspeção, o órgão regulador deve executar uma inspeção rápida, a qual nem sempre é possível dada a complexidade das PCIs. A tarefa pode ser ainda mais complexa se os inspetores não forem especialistas em eletrônica, acarretando apenas em uma inspeção visual que pode ser uma tarefa complicada para quem possui conhecimentos limitados de eletrônica. Dessa forma, um método capaz de auxiliar os inspetores através da detecção de modificações e regiões com suspeitas de fraude pode ser de grande valia para o estado e para os interesses do consumidor. Tal tipo de método deve conseguir operar em ambientes variados, sem requerer aparatos sofisticados de captura, ambiente com luz controlada ou posição fixa de câmera. O objeto de estudo deste trabalho é a detecção visual de anomalias em placas de circuito impresso, enquadrando-se nas detecções utilizando imagens.

A detecção de anomalias é um assunto extensivamente estudado na literatura, um dos problemas clássicos de Aprendizado de Máquina. Grande parte das técnicas consideradas estado da arte utilizam técnicas de Aprendizado Profundo em sua solução. As aplicações mais comuns envolvem detecção de anomalias em: vídeos (KIRAN *et al.*, 2018), imagens (ZHAI *et al.*, 2016; OLIVEIRA *et al.*, 2017; KUMAR, 2008; ABATI *et al.*, 2019; BHATTAD *et al.*, 2018), tráfego de redes de computadores (MIN *et al.*, 2018), áudio (CONTE *et al.*, 2012), series temporais (MUNIR *et al.*, 2019), monitoramento de páginas da internet (XU *et al.*, 2018), e telemetria de veículos espaciais (SAKURADA; YAIRI, 2014).

A dificuldade da detecção visual de anomalias poderia ser reduzida inserindo o problema em um ambiente controlado. Com tal ambiente é possível utilizar técnicas clássicas de processamento de imagens, como a subtração de imagens (CHANG; CHIANG, 2002; ARDHY;

HARIADI, 2016), detecção de contornos, entre outras. Entretanto, este tipo de abordagem é significativamente sensível a variações externas, como: variações de iluminação, ângulo, posicionamento, perspectiva, ou até mesmo a mudança da câmera. É importante desenvolver sistemas de tomada de decisão que funcionem em várias situações, ou que ofereçam ao menos níveis maiores de liberdade para a sua utilização. Assim, neste contexto técnicas de aprendizado de máquina se tornam ainda mais interessantes. Ao se utilizar de dados que expressem diversas situações do problema, as técnicas de aprendizado de máquina tendem a generalizar o problema de forma mais concisa (DUDA *et al.*, 2001; ALPAYDIN, 2009).

Em muitas soluções propostas para a detecção de anomalias, seja em imagens ou outros tipos de dados, é comum usar classificadores de uma classe (ZHAI *et al.*, 2016; HAWKINS, 1980; ABATI *et al.*, 2019). Com as instâncias normais, o classificador de uma classe consegue delimitar uma fronteira de probabilidade que define o conjunto normal da distribuição. Assim, qualquer anomalia submetida ao classificador estará fora da fronteira de probabilidade da distribuição normal. Diversos trabalhos já demonstraram a efetividade deste tipo de abordagem (OLIVEIRA *et al.*, 2017; ZHAI *et al.*, 2016; HAWKINS, 1980; ABATI *et al.*, 2019), porém esses classificadores requerem extratores de características que consigam representar o problema com detalhes. Muitas vezes esses extratores não conseguem representar todas as características que diferenciam o problema, por isso técnicas de Aprendizado Profundo surgem como uma opção (BERGMANN *et al.*, 2019; BERGMANN *et al.*, 2021; CAPIZZI *et al.*, 2015; AN; CHO, 2015; AKCAY *et al.*, 2018; BEGGEL *et al.*, 2019; AKCAY *et al.*, 2018; DEECKE *et al.*, 2018; AN; CHO, 2015). No caso de imagens, essas técnicas recebem as imagens como entrada e aprendem as características que melhor representam as amostras. Os *Autoencoders* (AEs) (HINTON; SALAKHUTDINOV, 2006) são técnicas de Aprendizado Profundo capazes de reconstruir imagens a partir de um processo de treinamento. Um AE pode ser treinado apenas com imagens normais, quando uma imagem com anomalias é submetida, sua reconstrução resultará em uma imagem sem anomalias, contanto que se utilize a função de custo apropriada para tal. Assim, o erro de reconstrução, i.e. a diferença das imagens de entrada e saída do *Autoencoder* pode revelar as anomalias.

Um AE seria capaz de detectar anomalias em imagens de PCI em ambiente com maior variação, eliminando a necessidade de ambientes controlados. Sem ambientes controlados, os sistemas de inspeção podem se tornar mais baratos e escaláveis. Sendo possível coletar imagens com qualquer câmera sem restrições de iluminação ou posicionamento. O problema da detecção de anomalias pequenas ou sutis é importante para diversas aplicações, principalmente voltadas

à indústria, como a inspeção de qualidade em uma linha de produção. Isso pode ser benéfico para a indústria de eletrônicos, pois diminuiria erros de fabricação que acarretam substituição de aparelhos. Também seria uma forma de inspecionar de forma mais rápida PCIs que podem estar sujeitas a fraudes, como no caso da adulteração de PCIs em bombas de combustível (OLIVEIRA *et al.*, 2017).

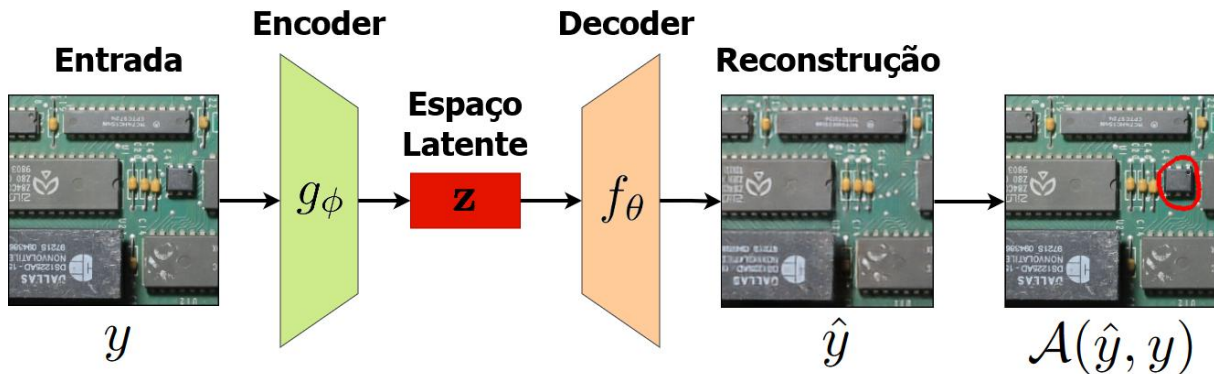
1.2 DEFINIÇÃO DO PROBLEMA

O problema abordado neste trabalho é a detecção de anomalias em imagens de placas de circuito impresso em ambientes não controlados. O método proposto utiliza aprendizado de uma classe, onde os modelos são treinados apenas com imagens livres de anomalias. Em estudos recentes, o problema de detecção de anomalias com a utilização de apenas instâncias normais durante o aprendizado é extensivamente abordado (BERGMANN *et al.*, 2019; BERGMANN *et al.*, 2021; CAPIZZI *et al.*, 2015; AN; CHO, 2015; AKCAY *et al.*, 2018; BEGGEL *et al.*, 2019; AKCAY *et al.*, 2018; DEECKE *et al.*, 2018; AN; CHO, 2015), porém em ambientes controlados, sem variação de perspectiva ou iluminação. A utilização de um ambiente controlado ou semi-controlado proporciona uma menor variabilidade intraclasses das imagens, representando um problema de menor complexidade, visto que as imagens não apresentam variações significativas na aparência dos objetos inspecionados. Trabalhos recentes (BERGMANN *et al.*, 2019; BERGMANN *et al.*, 2021) propuseram bases de imagens para a detecção de anomalias em ambiente industrial, o que proporcionou uma série de estudos e avanços recentes nessa área (BERGMANN *et al.*, 2019; SHI *et al.*, 2021; VENKATARAMANAN *et al.*, 2020; SATO *et al.*, 2019; WANG *et al.*, 2020; COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; TANG *et al.*, 2022).

As técnicas de aprendizado profundo utilizadas tem como objetivo detectar anomalias ou adulterações em placas de circuito impresso através de imagens capturadas em ambientes não controlados. Mais especificamente, o método proposto utiliza arquiteturas de *Autoencoders* convolucionais para detectar anomalias através da reconstrução de imagens. Essa arquitetura tem a capacidade de comprimir uma imagem de entrada em um vetor de características, também conhecido como espaço latente, e posteriormente reconstruir a imagem original a partir desse vetor. O método é fundamentado na hipótese de que: um modelo treinado apenas com imagens livre de anomalias será capaz de reconstruir apenas este tipo de instância. Consequentemente, quando o modelo recebe como entrada uma imagem contendo anomalias, ele não deverá ser

capaz de reconstruir imagem corretamente ou, se o fizer, a imagem resultante estará livre de anomalias. A Figura 1 ilustra o método de inferência utilizado neste trabalho.

Figura 1 – Processo de inferência executado por meio de uma técnica baseada na reconstrução, utilizando uma arquitetura de *Autoencoder* convolucional. Nesse contexto, o *Autoencoder* é treinado exclusivamente com imagens sem anomalias. Quando uma imagem contendo anomalias é fornecida como entrada, o *Autoencoder* produz uma saída em que as modificações não são reconstruídas. Posteriormente, por meio de uma função de comparação ou métrica de similaridade, a entrada e a saída são comparadas, permitindo a segmentação das anomalias.



Fonte: Autoria própria.

1.3 OBJETIVOS GERAIS

O objetivo geral deste trabalho é desenvolver uma abordagem para a detecção de anomalias em placas de circuito impresso por meio de imagens capturadas em ambientes não controlados, utilizando *Autoencoders* convolucionais que foram treinados exclusivamente com imagens livres de anomalias. Para tornar essa proposta mais clara e direcionada, o objetivo geral pode ser desdobrado em objetivos específicos da seguinte forma:

1. **Desenvolver um método robusto de detecção de anomalias em PCIs:** Envolve a criação de um método para a detecção de anomalias em ambientes não controlados. Isso inclui a definição de uma função de custo adequada e uma função de comparação entre a entrada e a reconstrução que seja eficaz na segmentação das anomalias.
2. **Analisar o comportamento da função de custo:** Este objetivo consiste em estudar como o desempenho do método varia com diferentes valores de peso atribuídos à função de custo, visando otimizar a detecção de anomalias.
3. **Criar um conjunto de dados representativo para a detecção de anomalias em PCIs:** A construção um conjunto de dados que demonstre a eficácia do método proposto na

inspeção de Placas de Circuitos Impressos em ambientes não controlados também é um dos objetivos específicos deste trabalho.

4. **Comparar o método proposto com métodos da literatura:** Realizar a comparação do método proposto com abordagens existentes na literatura para identificar suas diferenças, vantagens e desvantagens em relação aos métodos anteriormente propostos.
5. **Validar o método proposto em outras aplicações:** Além da detecção de anomalias em PCIs, este objetivo busca validar o método proposto em outras aplicações, utilizando conjuntos de dados públicos, demonstrando a versatilidade e a eficácia do método em diferentes contextos.

1.4 QUESTÕES DE PESQUISA

A hipótese central deste trabalho é de que um *Autoencoder* convolucional treinado apenas com imagens livre de anomalias, ao receber uma imagem com anomalia, a reconstruirá sem a anomalia. Entretanto, o desempenho do modelo é dependente das modificações contidas na imagem, ou ainda do objeto que está sendo inspecionado. As perguntas definidas nessa seção auxiliam a condução do desenvolvimento dos experimentos. As perguntas são definidas como:

- **Questão de Pesquisa (QP).01:** Quais as dificuldades encontradas ao se retirar o controle do ambiente na captura?
- **QP.02:** Existe diferença na detecção das anomalias de acordo com seu tamanho em relação a imagem?
- **QP.03:** O método proposto pode ser estendido para outros contextos ou objetos?
- **QP.04:** Quais as vantagens e desvantagens que o método apresenta em diferentes tipos de objetos?

Os resultados das questões serão apresentados no Capítulo 5.

1.5 CONTRIBUIÇÕES GERAIS DO MÉTODO

Conforme estabelecido na definição do problema, este trabalho emprega técnicas de aprendizado profundo para a detecção de anomalias em placas de circuito impresso, mais

especificamente utilizando a arquitetura de *Autoencoders* convolucionais. A aplicação dessas técnicas requer a definição de vários elementos essenciais, comuns às abordagens de aprendizado profundo, incluindo a arquitetura da rede e as funções de custo.

Além disso, como ilustrado na Figura 1, é crucial definir uma função de comparação eficaz, especialmente quando as imagens não são obtidas em ambientes controlados. Essa função de comparação desempenha um papel fundamental na identificação de anomalias, permitindo a diferenciação entre as características normais e as anomalias nas imagens capturadas em condições não controladas. Portanto, o desenvolvimento de uma métrica de comparação precisa e sensível é um dos aspectos críticos deste trabalho. Dessa forma, as principais contribuições deste trabalho, são:

- A definição de uma função de custo que combina função de custo de conteúdo e a função de erro quadrático médio para treinar arquiteturas baseadas em reconstrução através de *Autoencoder* convolucionais. Essa abordagem permite que o método seja treinado exclusivamente com imagens sem anomalias, tornando-o mais viável e prático para aplicações do mundo real, onde a obtenção de imagens com anomalias pode ser difícil ou custosa.
- A definição de uma função de comparação que pode ser utilizada para detectar e segmentar regiões que podem conter anomalias, através da comparação de uma entrada e sua reconstrução produzida pelo *Autoencoder* convolucional. A comparação entre as imagens é baseada em características de alto nível em vez de *pixels* individuais, permitindo a análise de estruturas ou regiões na imagem, de forma semelhante ao que é feito por seres humanos.
- A aplicação das funções de custo e comparação na construção de um método robusto para detectar modificações em placas de circuito impresso contendo distorções de perspectiva, ruídos e variações de iluminação. Isto torna o método proposto capaz de gerar resultados contundentes em situações comuns de aplicações reais. Por exemplo, o método pode ser usado na inspeção de placas de bombas de combustível em campo, onde imagens podem ser capturadas usando dispositivos móveis convencionais, sem a necessidade de controle rigoroso de iluminação e posição. Além disso, essa abordagem é aplicável em outras situações, como a inspeção de qualidade em ambientes industriais.
- Um conjunto de dados rotulado, contendo imagens de PCIs para o treinamento, avaliação e teste de métodos de detecção e segmentação de anomalias. O conjunto de dados

foi disponibilizado de forma pública (OLIVEIRA *et al.*, 2023), contendo imagens de resolução 4096×2816 *pixels*, sendo 1742 livres de anomalias e 55 imagens contendo modificações. As anotações das máscaras das anomalias foram disponibilizadas, para a devida comparação com outros métodos.

1.6 ESTRUTURA DO DOCUMENTO

Este trabalho é dividido em 5 capítulos.

O capítulo 2 apresenta o Estado da Arte, evidenciando os trabalhos relacionados a detecção de anomalias em imagens, destacando as metodologias empregadas tratadas em outros trabalhos.

Os materiais e métodos são apresentados no capítulo 3, onde são descritos o contexto e quais as técnicas desenvolvidas neste trabalho para a detecção de anomalias em placas de circuito impresso.

O capítulo 4 discute os resultados obtidos, onde os resultados são apresentados, analisados e são feitas as devidas considerações.

Por fim, no capítulo 5, são apresentadas as conclusões gerais do trabalho, detalhando o cumprimento dos objetivos propostos. O capítulo também direciona as próximas abordagens a serem tratadas em trabalhos futuros.

2 ESTADO DA ARTE

O Estado da Arte em detecção de anomalias e modificações abrange uma ampla variedade de aplicações em diversos campos de conhecimento. Entre as aplicações mais comuns, estão: vídeos (KIRAN *et al.*, 2018), imagens (KUMAR, 2008; ABATI *et al.*, 2019; ZHAI *et al.*, 2016; BHATTAD *et al.*, 2018), tráfego de redes de computadores (MIN *et al.*, 2018), áudio (CONTE *et al.*, 2012), e outros (MUNIR *et al.*, 2019; XU *et al.*, 2018; WU *et al.*, 2015; SAKURADA; YAIRI, 2014). Cada uma dessas aplicações apresenta abordagens diferentes conforme a natureza dos dados. Por exemplo, em vídeos as anomalias são contextuais, visto que são necessários vários quadros para a identificação de todo um contexto, e por consequência a identificação da anomalia. Por outro lado, a detecção de anomalias em imagens tende a ser mais pontual, uma vez que a anomalia pode ser identificada no contexto de uma única imagem. Essa abordagem é vantajosa em cenários onde a detecção de anomalias não depende de informações temporais e onde cada imagem é avaliada de forma independente. Além disso, a forma de abordar o problema e a disponibilidade dos dados influenciam a metodologia e os resultados dos estudos levantados. Como o objetivo deste trabalho está em detecção de anomalias em imagens, foram considerados trabalhos com este mesmo foco, especialmente aqueles que fazem o uso de técnicas e métodos que envolvem aprendizado profundo. Muitos desses métodos aproveitam o aprendizado profundo devido à sua eficácia na extração de características complexas e na modelagem de padrões sutis em imagens.

O levantamento destes trabalhos foi conduzido com o objetivo de responder quatro questões:

- **Q1:** Quais são os métodos para a detecção de anomalias em imagens?
- **Q2:** Quais as vantagens e desvantagens de cada método?
- **Q3:** Quais são as aplicações e como as anomalias são definidas nelas?
- **Q4:** Quais as técnicas empregadas em cada método?
- **Q5:** Como o problema é abordado para a inspeção de PCIs?

2.1 MÉTODOS PARA A DETECÇÃO DE ANOMALIAS

Os métodos encontrados na literatura podem ser divididos conforme dois objetivos principais de detecção em imagens: (i) dados fora da distribuição (*Out-of-Distribution*), e (ii) anomalias ou modificações.

A detecção de dados fora da distribuição é utilizada para identificar imagens que não pertencem à um conjunto ou classe específica, ou ainda imagens que sofreram algum tipo de modificação que alteram suas propriedades e afetam a predição de modelos de aprendizado de máquina — como as redes neurais, por exemplo. O foco principal dessas técnicas é manter a homogeneidade dos conjuntos de imagens, e também questões de segurança envolvendo a predição em redes neurais (SZEGEDY *et al.*, 2013; GOODFELLOW *et al.*, 2015; HENDRYCKS; GIMPEL, 2017; LEE *et al.*, 2018; YUAN *et al.*, 2019). Manter a homogeneidade dos dados é importante tanto para o treinamento de novos modelos, ou a identificação de problemas em aplicações que envolvem a utilização de imagens — como sistemas de reconhecimento facial ou identificação de determinados objetos. Uma prática comum nesses trabalhos é utilizar bases de imagens de classificação, como MNIST (LECUN *et al.*, 1998), CIFAR10 (KRIZHEVSKY; HINTON, 2009), e ImageNet (DENG *et al.*, 2009a). Nessa abordagem uma classe é rotulada como “normal”, e um conjunto arbitrário de outras classes é rotulado como “anomalias” para treinar modelos de detecção de anomalias. Durante a fase de testes, se verifica a capacidade do modelo treinado em identificar se uma imagem pertence à classe normal ou anomalia. No entanto, essa abordagem trata imagens inteiras como anomalias, o que pode não ser adequado para situações em que é necessário detectar pequenas anomalias ou modificações. Enquanto esse tipo de abordagem fornece uma grande quantidade de imagens para treinamento e teste, as instâncias anômalas são significativamente diferentes das normais, o que pode ser insuficiente para sistemas de inspeção onde é necessário identificar apenas anomalias sutis. Já as questões de segurança envolvem a possibilidade de burlar sistemas de aprendizado de máquina, com técnicas como *Adversarial Attack* (SZEGEDY *et al.*, 2013; YUAN *et al.*, 2019) e *Distribution Shifts* (HENDRYCKS; GIMPEL, 2017; LEE *et al.*, 2018). De forma geral, nesse tipo de detecção as anomalias não são visíveis para humanos, os estudos demonstram que a adição de alguns dados que não alteram a imagem visualmente influenciam no desempenho dos classificadores. A Figura 2 demonstra como a simples inserção de ruídos imperceptíveis ao olho humano afeta o desempenho de uma rede neural de classificação.




Figura 2 – Exemplo de anomalias fora da distribuição. Nesse exemplo, uma Rede Convolutiva classificou corretamente a imagem de um Panda, com 57,7% de confiança, ao adicionar um ruído imperceptível para humanos na imagem, a mesma rede passou a classificar a imagem como “Gibão” (uma espécie de primata) com 99,3% de confiança.

Fonte: Adaptado de (GOODFELLOW *et al.*, 2015)

Na detecção de anomalias e modificações, o foco principal é identificar problemas em objetos ou ambientes que fogem de um padrão pré-determinado. Esse tipo de método é utilizado em aplicações como: identificação de intrusos ou objetos em cenas de vigilância (VU *et al.*, 2019; ZAHEER *et al.*, 2020), identificação de falhas em equipamentos (OLIVEIRA *et al.*, 2017), inspeção visual de produtos (BERGMANN *et al.*, 2019; SHI *et al.*, 2021; VENKATARAMANAN *et al.*, 2020; SATO *et al.*, 2019; WANG *et al.*, 2020; COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; TANG *et al.*, 2022), identificação de anomalias em imagens de satélite (TILON *et al.*, 2020; REMBOLD *et al.*, 2013; TOUATI *et al.*, 2020), detecção de patologias em imagens médicas (SHVETSOVA *et al.*, 2021; TIAN *et al.*, 2021), entre outras (CAPIZZI *et al.*, 2015; AKCAY *et al.*, 2018). Nesse tipo de abordagem, um modelo é construído para identificar a presença de modificações em um objeto ou ambiente. De forma geral, o ambiente ou objeto não é alterado por completo, mas sim uma pequena parte ou região que foge de um padrão pré-estabelecido. Por exemplo, dado um sistema de inspeção industrial voltado para barras de chocolate, caso uma barra esteja quebrada ou apresente uma parte faltante, ela seria considerada por esses modelos um objeto anômalo. Neste caso, alguns métodos propõe apenas a classificação a nível de imagem como contendo uma anomalia ou não, enquanto outros fazem a detecção ou segmentação do local exato da anomalia a nível de *pixels* ou regiões. Como o objetivo deste trabalho é a localização de anomalias ou modificações em imagens, os métodos apresentados neste capítulo são focados na abordagem de segmentação de anomalias e modificações.

As técnicas de detecção de anomalias e modificações em imagens encontradas na literatura podem ser divididas em duas categorias principais, conforme sua abordagem: clas-

sificação supervisionada clássica e classificação de uma única classe. Os métodos baseados em classificação clássica (OLIVEIRA *et al.*, 2017; GOLAN; EL-YANIV, 2018; KAWACHI *et al.*, 2018) seguem a abordagem tradicional de aprendizado supervisionado, onde as entradas são classificadas em diferentes categorias com base em suas características. Embora essa abordagem seja eficaz, ela apresenta a limitação de exigir um conjunto completo de imagens de todas as classes, incluindo anomalias e imagens sem anomalias. Isso pode ser problemático na detecção de anomalias, pois pode ser desafiador ou até impossível obter uma grande quantidade de imagens de anomalias devido a custos ou à falta de conhecimento sobre todas as possíveis modificações. Por outro lado, na abordagem de classificação de uma única classe (TAX, 2001) as instâncias normais são utilizadas para delimitar um hiperplano que define a classe normal. Durante o processo de inferência, qualquer instância que se encontre fora desse hiperplano pode ser identificada como uma anomalia.

A classificação de uma classe pode ser utilizada de diversas formas, sendo as mais comuns encontradas na literatura: classificação binária (OLIVEIRA *et al.*, 2017; LI *et al.*, 2020; SATHIASEELAN *et al.*, 2021; ADIBHATLA *et al.*, 2020), reconstrução (BERGMANN *et al.*, 2019; SHI *et al.*, 2021; VENKATARAMANAN *et al.*, 2020; SATO *et al.*, 2019; WANG *et al.*, 2020; TANG *et al.*, 2022) e similaridade de características (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; LI *et al.*, 2021). Na classificação binária, a saída é representada por um valor, e um limiar é definido para determinar se uma imagem de entrada contém uma anomalia ou não. Por outro lado, nos métodos de reconstrução, um modelo é treinado para reconstruir apenas imagens livres de anomalias. Quando recebe uma imagem contendo uma anomalia, o modelo não consegue reconstruí-la perfeitamente, o que leva à detecção da anomalia. Além disso, a comparação entre a imagem de entrada e a imagem reconstruída pode ser usada para localizar e segmentar a região onde a anomalia está presente. Esses métodos frequentemente fazem uso de variações de *Autoencoders* profundos, que têm se mostrado eficazes em várias soluções recentes (BERGMANN *et al.*, 2019; SHI *et al.*, 2021; VENKATARAMANAN *et al.*, 2020; SATO *et al.*, 2019; WANG *et al.*, 2020). A principal vantagem dos métodos de reconstrução é a interpretabilidade, já que os resultados estão intrinsecamente ligados à capacidade de reconstrução dos modelos. Porém, esse tipo de abordagem pode apresentar dificuldades para reconstruir imagens de alta resolução e com elementos de alta complexidade.

Os métodos de similaridade de características utilizam de modelos pré-treinados para

outras tarefas, como classificação de imagens, para extrair descritores de características. Essas características são utilizadas para criar modelos matemáticos ou probabilísticos (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; TANG *et al.*, 2022) que identificam a presença ou ausência de anomalias. Assim como nos métodos de reconstrução, esses métodos podem ser usados tanto para classificar a imagem como para localizar e segmentar anomalias. Os métodos mais recentes (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; TANG *et al.*, 2022) utilizam redes convolucionais treinadas para a classificação de objetos em base de imagens de larga escala para extrair as características, e definem os próprios modelos matemáticos para a detecção e segmentação de anomalias. Uma das vantagens desse tipo de método é a relativa facilidade de construção dos modelos, pois não exigem longos períodos de treinamento em placas de vídeo. Entretanto, a interpretabilidade desses métodos pode ser desafiadora, o que pode ser importante em algumas aplicações, principalmente de cunho industrial.

2.2 APLICAÇÕES DE DETECÇÃO DE ANOMALIAS

No contexto das aplicações de detecção de anomalias em imagens, muitos estudos concentram-se em bases de dados clássicas, como: MNIST (LECUN *et al.*, 1998), CIFAR (KRIZHEVSKY; HINTON, 2009) e ImageNet (DENG *et al.*, 2009b). A base MNIST consiste em imagens em tons de cinza de dígitos manuscritos de 0 a 9 (Figura 3 (a)), enquanto as bases CIFAR (Figura 3 (b)) e ImageNet contêm imagens coloridas de várias classes de objetos diferentes. Essas bases de dados permitem abordagens em que uma ou mais classes são consideradas como normais, enquanto todas as outras são tratadas como anomalias. Esse tipo de abordagem é aplicado em trabalhos como os Szegedy *et al.* (2013), Goodfellow *et al.* (2015), Hendrycks e Gimpel (2017), Lee *et al.* (2018), Yuan *et al.* (2019). Assim, as anomalias são definidas como exemplos que estão totalmente fora da distribuição das amostras normais. Embora essa abordagem seja interessante para resolver problemas como a rotulagem de grandes conjuntos de dados, ela não reflete a maioria dos desafios encontrados em problemas reais de inspeção visual. Em situações do mundo real, as anomalias costumam ser sutis e ocupar uma pequena proporção em relação ao tamanho total da imagem, tornando-se facilmente confundidas com os dados normais. Como resultado, alguns estudos de ponta focam em propor novas técnicas para a detecção de anomalias, mas essas técnicas geralmente proporcionam melhorias marginais e não

abordam casos em que as anomalias são sutis em relação ao tamanho global da imagem.

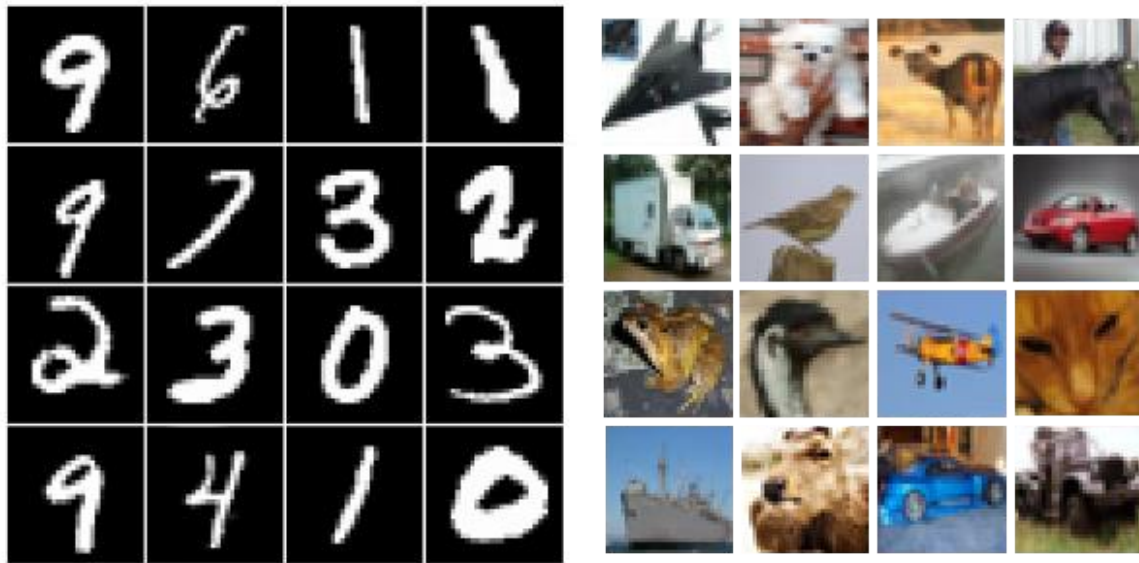


Figura 3 – Exemplos das bases (a) MNIST e (b) CIFAR-10.
Fonte: (KRIZHEVSKY; HINTON, 2009) e (LECUN *et al.*, 1998)

Alguns estudos se concentram em aplicações em que as anomalias são tão sutis a ponto de serem desafiadoras de distinguir de amostras normais. Recentemente, a base de imagens MVTEC-AD, proposta por Bergmann *et al.* (2019), Bergmann *et al.* (2021), foi criada com o objetivo de servir como um referencial para técnicas de detecção de anomalias em imagens. Essa base de dados reúne uma ampla variedade de imagens que incluem objetos e texturas. Para fins de treinamento e teste, são disponibilizadas imagens sem anomalias, bem como imagens contendo anomalias. Dessa forma, diversos estudos, como os conduzidos por Bergmann *et al.* (2019), Shi *et al.* (2021), Venkataramanan *et al.* (2020), Sato *et al.* (2019), Wang *et al.* (2020), Cohen e Hoshen (2020), Defard *et al.* (2021), Wang *et al.* (2021a), Roth *et al.* (2022), Hermann *et al.* (2022), Tang *et al.* (2022), adotaram a base de imagens MVTEC-AD como o foco central de suas pesquisas. As abordagens baseadas em métodos de uma única classe são amplamente aplicadas com o uso dessa base de dados. A maioria dessas técnicas se baseia nos métodos de similaridade de características (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022; TANG *et al.*, 2022), embora também haja abordagens que utilizam métodos de reconstrução (BERGMANN *et al.*, 2019; SHI *et al.*, 2021; VENKATARAMANAN *et al.*, 2020; SATO *et al.*, 2019; WANG *et al.*, 2020).

Uma série de outros trabalhos também abordam a detecção de anomalias em uma variedade de cenários e contextos. Oliveira *et al.* (2017) se concentra na detecção de anomalias

em placas de circuito impresso (PCIs) montadas, enquanto Ardhy e Hariadi (2016), Shi *et al.* (2020) abordam a detecção de anomalias em PCIs não montadas. O estudo proposto por Beggel *et al.* (2019) se dedica à detecção de armas em imagens de Raio-X de aeroporto e também avalia as técnicas propostas em bases de dados clássicas. Por sua vez, Haselmann *et al.* (2018) se concentram na detecção de anomalias em superfícies de plástico. A reconstrução de faces com anomalia é explorada por Bhattad *et al.* (2018), utilizando uma base de imagens CelebA (LIU *et al.*, 2015) contendo rostos de celebridades. Além disso, a base de imagens UCSD Ped2 (CHAN; VASCONCELOS, 2008) é amplamente empregada para a detecção de anomalias em cenas urbanas (SHAO *et al.*, 2014; PRASAD *et al.*, 2017; LI *et al.*, 2020).

2.3 TÉCNICAS PARA A DETECÇÃO DE ANOMALIAS

A literatura oferece uma grande variedade de técnicas para abordar a detecção de anomalias e modificações, mas a grande maioria dos estudos recentes emprega técnicas de aprendizado profundo. Os estudos que tratam o problema de detecção de anomalias ou modificações através da classificação clássica, em sua maioria, utilizam redes neurais profundas (GOLAN; EL-YANIV, 2018; CAPIZZI *et al.*, 2015; KAWACHI *et al.*, 2018) ou Máquinas de Vetor de Suporte, do inglês *Support Vector Machines* (SVM) (OLIVEIRA *et al.*, 2017), tanto para classificação multi-classe quanto para uma classe. Por outro lado, as técnicas de uma classe baseadas em reconstrução se resumem ao uso de *Autoencoders*, e suas variações (GOODFELLOW *et al.*, 2014; AN; CHO, 2015; BEGGEL *et al.*, 2019; AKCAY *et al.*, 2018; DEECKE *et al.*, 2018; AN; CHO, 2015). As técnicas de uma classe baseadas em similaridade de características têm uma abordagem mais variada, envolvendo redes neurais profundas (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a), *Autoencoders* (TANG *et al.*, 2022; GONG *et al.*, 2019) e até arquiteturas mais recentes, como os *Transformers* visuais (DOSOVITSKIY *et al.*, 2020).

2.3.1 Métodos de classificação

Dentre as técnicas de classificação de imagens clássicas, as mais comuns na literatura envolvem o uso de redes neurais convolucionais, bem como métodos tradicionais como SVM (OLIVEIRA *et al.*, 2017) e k vizinhos mais próximos, do inglês *k Nearest Neighbors* (k-NN) (LÓPEZ *et al.*, 2005; PERNKOPF, 2004). Em geral, essas abordagens fazem uso de conjuntos de dados contendo exemplos de imagens com e sem anomalias para treinar os classificadores de

forma supervisionada, com a classificação normalmente sendo realizada a nível de imagem.

Em López *et al.* (2005), os autores aplicam o k-NN para classificar imagens de azulejos de cerâmica em normal ou anomalo com base em características cromáticas, enquanto Pernkopf (2004) utilizam o k-NN para classificar superfícies defeituosas de aço com base em informações de dispersão de campos aleatórios de Markov. O trabalho conduzido por Oliveira *et al.* (2017) emprega SVM e características SIFT (LOWE, 2004) para detecção de anomalias em uma base de dados própria, onde o treinamento envolve imagens normais e imagens com anomalias geradas artificialmente. Em uma abordagem similar, Li *et al.* (2021) também geram anomalias de forma artificial por meio de técnicas de aumento de dados para treinar um classificador. Ambos Oliveira *et al.* (2017) e Li *et al.* (2021) dividem as imagens em várias regiões e geram classificações individuais para obter uma aproximação da detecção de anomalias.

Golan e El-Yaniv (2018) detectam anomalias nas bases MNIST, CIFAR e CatsVS-Dogs (ELSON *et al.*, 2007) aplicando diversas transformações nas imagens de treinamento e teste. Por meio de uma rede neural multiclases, onde as saídas representam classificações das transformações, eles definem uma equação que calcula uma pontuação de anomalia para as amostras. Já Wan *et al.* (2022) utilizam um número limitado de imagens contendo anomalias em um cenário de treinamento supervisionado, enfrentando um desequilíbrio significativo na base de dados. Além disso, vários estudos aplicam redes neurais convolucionais para a classificação de imagens com e sem defeitos em uma ampla gama de aplicações, que vão desde a detecção de frutas imperfeitas (CAPIZZI *et al.*, 2015) até a detecção de anomalias em manufatura de produtos industriais (KUMAR, 2003; KUO *et al.*, 2003; YIN *et al.*, 2009; ZHANG *et al.*, 2010). Alguns desses trabalhos também fazem uso de arquiteturas semelhantes a *Autoencoders*, extraíndo informações das saídas ou do espaço latente. Por exemplo, em Kawachi *et al.* (2018), são empregados *Variational Autoencoder* (VAE) para identificar anomalias desconhecidas com base em anomalias conhecidas na base de imagens MNIST. As informações contidas no espaço latente são usadas para medir a semelhança de uma imagem com as anomalias conhecidas.

Os métodos de classificação também podem ser aplicados considerando apenas uma classe. Nesses métodos, o modelo de classificação busca definir uma fronteira de classificação exclusivamente para amostras normais. Embora essas técnicas tenham sido amplamente utilizadas na literatura (PARZEN, 1962; SCHÖLKOPF *et al.*, 2001), elas apresentavam deficiências evidentes em dados de alta dimensionalidade, como imagens, devido à sua má escalabilidade computacional e ao fenômeno conhecido como a “maldição da dimensionalidade” (RUFF *et al.*,

2018). Essas técnicas costumam apenas classificar a imagem conforme a pontuação retornada por um classificador (RUFF *et al.*, 2019; GHAFORI; LECKIE, 2020). Dessa forma, a detecção de anomalias é realizada a nível de imagem, o que impossibilita a detecção e segmentação. Porém, alguns trabalhos como em Ruff *et al.* (2018), Wu *et al.* (2019) adotam uma abordagem mais granular, dividindo a imagem em diversas pequenas regiões e realizando a classificação de cada uma dessas regiões como anomalia ou não. Isso permite uma aproximação da segmentação, já que cada região é tratada de forma independente. A maioria dessas técnicas é usada para a detecção de anomalias fora de contexto. Porém o conceito da utilização de apenas uma classe durante o treinamento é empregado em outras abordagens, como técnicas de reconstrução e detecção por similaridade de características.

2.3.2 Reconstrução

Os trabalhos focados em técnicas de reconstrução, em sua grande maioria, baseiam-se em arquiteturas de *Autoencoders*. Nessas estruturas, o princípio fundamental é comprimir as imagens em um espaço latente e, em seguida, reconstruí-las de forma que a saída seja uma reprodução fiel da entrada. Ao comparar a entrada original com a saída reconstruída, é possível identificar anomalias. A literatura apresenta uma variedade de *Autoencoders* diferentes e técnicas de treinamento que complementam o aprendizado, e.g.: *Generative Adversarial Network* (GAN), VAE e *Inpainting* AEs. Essas variantes de *Autoencoders* trazem características diferentes que podem ser vantajosas para a detecção de anomalias em diferentes contextos e tipos de dados.

Diversos trabalhos recentes (BERGMANN *et al.*, 2019; BERGMANN *et al.*, 2018; GONG *et al.*, 2019; TANG *et al.*, 2022) aplicam a detecção de anomalias em imagens, usando *Autoencoders*. De forma geral, a diferença entre os trabalhos que utilizam esse tipo de arquitetura convolucional está na aplicação de diferentes mecanismos nas camadas da rede, ou na função de custo utilizada. Em Shi *et al.* (2021) a função de custo utilizada foi L2-norm, assim como em Bergmann *et al.* (2018) e Bergmann *et al.* (2019), que além da L2-norm utilizaram a *Structural Similarity Index Measure* (SSIM) (WANG *et al.*, 2004). Já Gong *et al.* (2019) usa a função de custo por entropia, além de também propor a utilização de mecanismos de atenção no espaço latente para selecionar características mais importantes para a reconstrução. Outra contribuição proposta por Shi *et al.* (2021) é a utilização de características extraídas de redes convolucionais pré-treinadas como entrada do *Autoencoder*, assim a saída não requer imagens com alto nível de detalhes para a comparação entre entrada e saída. A mesma abordagem utilizando características

extraídas de outra rede neural profunda é utilizada por (TANG *et al.*, 2022), sendo que nesse artigo os autores propõem o uso de uma arquitetura com *Skip Connections*. De forma geral, um dos problemas apresentados no uso de *Autoencoders* para a reconstrução é a geração de saídas com baixa resolução, o que pode gerar regiões que representam detecções falsas ao se comparar com a saída. Além disso, devido a compactação de informações no espaço latente, regiões de alta frequência podem apresentar problemas na reconstrução.

Trabalhos mais recentes (AKCAY *et al.*, 2018; DEECKE *et al.*, 2018; BEGGEL *et al.*, 2019; SABOKROU *et al.*, 2018; PIDHORSKYI *et al.*, 2018) abordam a utilização de *Adversarial Generative Networks* (GOODFELLOW *et al.*, 2014). Beggel *et al.* (2019) usam um *Autoencoder* como gerador e uma rede profunda como discriminador, as informações do espaço latente na rede discriminadora são usadas para isolar as anomalias em regiões de baixa similaridade. A detecção das anomalias é a combinação do erro de reconstrução e a probabilidade das amostras extraídas no espaço latente. No trabalho de Akcay *et al.* (2018) a detecção de anomalias é feita sobre imagens de bagagem em aparelhos de Raio-X de aeroportos, onde também é abordado o uso de *Generative Autoencoders*, bem como o uso de informações do espaço latente e imagens de reconstrução. O estudo de Deecke *et al.* (2018) também utiliza GANs, porém sem *Autoencoders*, mas apenas Redes Neurais Profundas. Os modelos utilizando GANs costumam apresentar um processo de treinamento complexo (GOODFELLOW *et al.*, 2014), podendo apresentar alguns comportamentos comuns, como: (i) não convergir, dado a complexidade do problema; (ii) o gerador gerar uma variedade limitada de amostras que podem não generalizar o problema; (iii) o discriminador apresentar um aprendizado tão eficaz que faz com que o gerador pare de aprender a gerar amostras mais sofisticadas; e (iv) ser altamente sensível aos parâmetros definidos.

Outra técnica geradora abordada na literatura por An e Cho (2015), Venkataramanan *et al.* (2020), Sato *et al.* (2019) são os *Variational Autoencoders*. Diferente das GANs, os VAEs utilizam informações de outras amostras do treinamento no espaço latente para melhorar a etapa de reconstrução no decodificador. O trabalho de An e Cho (2015) foi um dos primeiros a utilizar essa técnica para a detecção de anomalias em imagens, utilizando como métrica um limiar de pontuação da reconstrução após verificar a eficácia do VAE no conjunto de teste. Abati *et al.* (2019) também aplicam uma técnica geradora na detecção de anomalias em imagens. A vantagem dos VAEs é que são mais fáceis de treinar que as GANs, onde o processo é similar a qualquer outro *Autoencoder* convolucional.

Outro tipo de técnica utilizada na literatura é a de *Inpainting Autoencoders* (XIE *et*

al., 2012). Originalmente, esse tipo de técnica foi desenvolvido para corrigir partes ausentes ou deterioradas de imagens através de um processo de reconstrução. A peculiaridade dessa técnica reside principalmente nos dados de treinamento, uma vez que as arquiteturas utilizadas não apresentam características distintas em comparação com outros tipos de *Autoencoders*. Nessa técnica, os dados de entrada no treinamento são deliberadamente deteriorados ou danificados, assim o objetivo do modelo é reconstruir uma imagem sem a deterioração empregada na entrada, minimizando a diferença entre a imagem original e a versão deteriorada. Bhattad *et al.* (2018) abordaram a detecção de anomalias utilizando *Inpainting Autoencoders*, aplicando a detecção de anomalias em imagens de rostos. Durante o treinamento, os autores deterioraram as imagens inserindo quadrados brancos de tamanho 32×32 aleatoriamente nas imagens de tamanho 128×128 . Haselmann *et al.* (2018) apresentam outro trabalho que aborda o uso de técnicas de *Inpainting*, com aplicação na detecção de anomalias em imagens de superfície, mas nesse caso, utilizaram uma arquitetura baseada em Redes Convolucionais Profundas. Técnicas que utilizam *Inpainting* têm a vantagem de serem relativamente simples de implementar, visto que é necessária apenas a adição de ruídos que sobreponham o conteúdo da imagem, como quadrados, linhas, ou estruturas aleatórias. No entanto, dependendo da complexidade das imagens as regiões reconstruídas podem aparecer borradas e com deformações visíveis.

2.3.3 Similaridade de características

Os métodos baseados em similaridade de características têm sido amplamente explorados na literatura. Vários estudos recentes (COHEN; HOSHEN, 2020; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022) adotam esse tipo de técnica para detectar e localizar anomalias, frequentemente aplicando-a à base de dados MVTEC-AD. Esses métodos são baseados em dois componentes principais: (i) vetores de características de uma imagem ou suas regiões, e (ii) um método de estimativa de similaridade para identificar imagens ou regiões anômalas. Os vetores de características podem ser de descritores tradicionais (XIE; MIRMEHDI, 2007; BÖTTGER; ULRICH, 2016; CARRERA *et al.*, 2016b; CARRERA *et al.*, 2016a) ou características extraídas de redes neurais (COHEN; HOSHEN, 2020; LI *et al.*, 2021; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022). Assim como a reconstrução, esses métodos utilizam apenas imagens sem anomalias, fazendo com que o método de estimativa de similaridade estabeleça uma distribuição normal que descreva as características das imagens sem anomalia. Dessa forma, ao receber uma imagem contendo

anomalias, o modelo identifica diferenças e, conseqüentemente, a presença de anomalias. Embora amplamente utilizada e com resultados promissores, esse tipo de método pode apresentar desafios em termos de interpretabilidade, visto que são gerados com base em descritores de características pouco intuitivos.

Os métodos de estimativa de similaridade mais utilizados estabelecem um modelo através de uma distribuição Gaussiana usando a média e variância das características normais (DEFARD *et al.*, 2021; LI *et al.*, 2021; WANG *et al.*, 2021a; HERMANN *et al.*, 2022), ou ainda usando técnicas de clusterização (COHEN; HOSHEN, 2020; ROTH *et al.*, 2022). Para melhorar o desempenho e permitir a localização de anomalias, as técnicas mais recentes (COHEN; HOSHEN, 2020; LI *et al.*, 2021; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; ROTH *et al.*, 2022; HERMANN *et al.*, 2022) adotam estratégias de detecção multi-escala. Nessa abordagem, a detecção de anomalias resulta da combinação dos resultados de múltiplos modelos, cada um derivado de diferentes regiões da imagem e com diferentes tamanhos de janela. No entanto, essa é uma abordagem que pode consumir muito tempo e recursos computacionais, tanto durante a criação do método de estimativa de similaridade, quanto na inferência, especialmente quando se utiliza redes neurais profundas para a extração de características. Além disso, como cada região é avaliada independentemente, pode não ser possível localizar anomalias utilizando informações de contexto global da imagem. A Figura 4 demonstra o método multi-escala proposto por Defard *et al.* (2021).

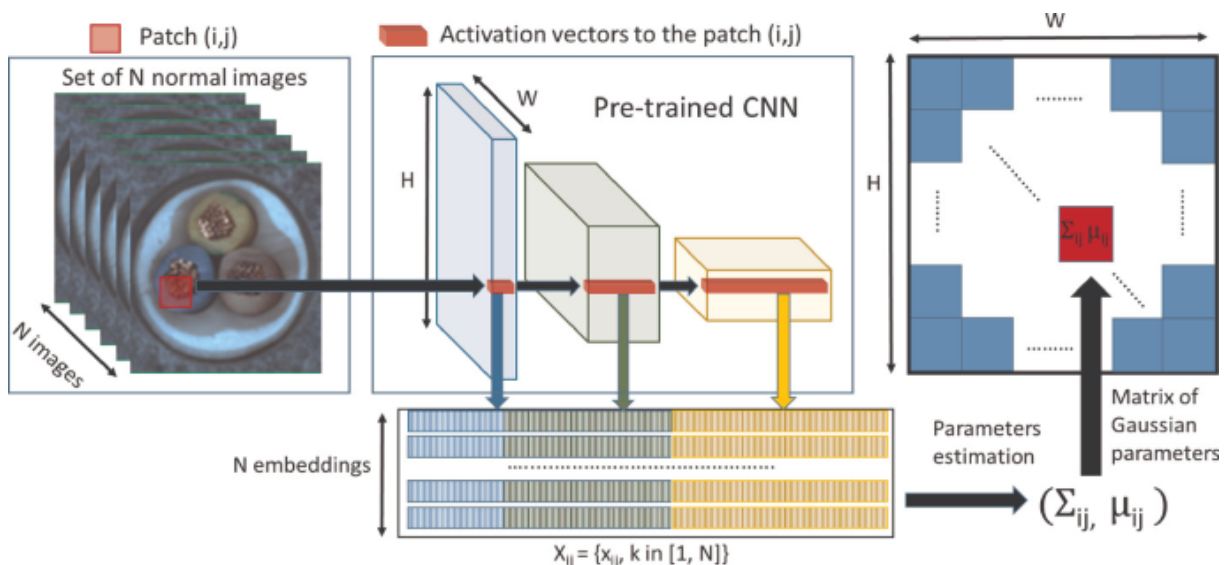


Figura 4 – Método multi-escala proposto por Defard *et al.* (2021), onde o vetor de características é extraído por uma rede neural profunda, e o método de estimativa de similaridade utiliza informações da distribuição Gaussiana dos dados.

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

2.4 DETECÇÃO DE ANOMALIAS EM PCI

Diversos estudos na literatura se dedicam à detecção de anomalias em Placas de Circuitos Impressos (PCIs) por meio de inspeção visual. Técnicas utilizando aprendizado de máquina são as mais abordadas em trabalhos recentes (OLIVEIRA *et al.*, 2017; LI *et al.*, 2020; LI *et al.*, 2019; ADIBHATLA *et al.*, 2020; SHI *et al.*, 2020; SATHIASEELAN *et al.*, 2021), enquanto outros trabalhos abordam o problema utilizando algoritmos de processamento de imagens (ZHU *et al.*, 2018; TSAI; HUANG, 2018; CHAUDHARY *et al.*, 2017). A maioria desses estudos se concentra na detecção de anomalias em PCIs não montadas, ou seja, a inspeção é realizada na placa antes da inserção e solda de componentes. A Figura 5 mostra a diferença entre uma PCI não montada e montada. Nessas situações, o objetivo principal é identificar anomalias, tais como: curto-circuitos, circuitos abertos, corrosão, protrusão e ausência de buracos para a inserção de componentes. A maioria dos métodos propostos requer algum nível de controle de captura do ambiente para detectar as anomalias, principalmente quanto à iluminação. Além disso, alguns desses métodos adotam uma abordagem supervisionada, o que pode limitar sua aplicabilidade a determinados tipos de defeitos ou componentes específicos.




Figura 5 – Exemplos de PCIs sem e com montagem. O que diferencia os dois tipos é a solda ou montagem dos componentes.

Fonte: Adaptado de (SHI *et al.*, 2020) e (LU *et al.*, 2020)

As principais técnicas tradicionais de visão computacional utilizadas nos trabalhos, são:

subtração de imagens, operações morfológicas e análise de características. A maioria desses estudos utiliza imagens de referência sem anomalia como base, comparando-as com as imagens a serem testadas. Zhu *et al.* (2018) aplica transformações morfológicas na subtração de imagens binárias entre a imagem analisada e uma referência, em seguida classifica a imagem analisada em várias classes de defeitos usando informações dos *pixels* da imagem binária. Já Tsai e Huang (2018) utilizam a Transformada de Fourier para identificar diferenças entre referências e a imagem testada. (CHAUDHARY *et al.*, 2017) utiliza características *From Accelerated Segment Test* (FAST) (ROSTEN; DRUMMOND, 2006) e a soma da diferença dos quadrados para identificar classes de anomalias.

As técnicas empregando aprendizado de máquina têm uma variação de métodos, com métodos tradicionais onde se aplicam extratores de características e classificadores (OLIVEIRA *et al.*, 2017; LI *et al.*, 2020), e outros usando aprendizado profundo (LI *et al.*, 2019; ADIBHATLA *et al.*, 2020; LI *et al.*, 2019; SATHIASEELAN *et al.*, 2021). Majoritariamente, os trabalhos apresentam abordagens supervisionadas, onde é necessário imagens de todas as classes para o treinamento. Oliveira *et al.* (2017) propuseram um método de inspeção para detectar fraudes em PCIs de bombas de combustível empregando características SIFT e SVM. Já Li *et al.* (2020) fazem a inspeção visual em imagens de profundidade da posição de componentes nas PCIs, o trabalho usa *Random Forests* (BREIMAN, 2001) para segmentar e classificar os componentes. O trabalhos de Adibhatla *et al.* (2020) e Li *et al.* (2019) utilizam, respectivamente, Tiny YOLOv2 e uma versão modificada do YOLOv3 para detectar alguns componentes das PCIs montadas, sendo que a falta de tais componentes indicam as anomalias. Com o mesmo tipo de proposta, Sathiaseelan *et al.* (2021) introduzem um detector de objetos chamado ECLAD-Net inspirado em outros detectores como *Region Based Convolutional Neural Networks* (R-CNN) (GIRSHICK *et al.*, 2014) e *Single-Shot Detector* (SSD) (LIU *et al.*, 2016), especializado para a detecção de componentes em PCIs. O estudo conduzido por Volkau *et al.* (2019) aborda o problema da detecção de anomalias em PCIs por meio da análise de características de similaridade. Eles utilizam a arquitetura VGG16 para extrair características das imagens e, com base nessas características, identificam regiões com alta probabilidade de conter defeitos. Shi *et al.* (2020) utilizam GAN para detectar anomalias em PCIs não montadas, usando apenas imagens livres de anomalias no treinamento. Os autores propõem um *Autoencoder* que faz a reconstrução da imagem, porém a imagem reconstruída passa por um *Encoder* que gera um vetor de características, que por fim são comparadas com as imagens sem anomalia.

Um estudo de particular relevância para este trabalho é o método proposto em Oliveira *et al.* (2017), que aborda o mesmo problema apresentado. Neste trabalho, foi empregado o mesmo método para lidar com variações no ângulo da câmera, e o mesmo princípio de particionamento da placa para analisar a placa em regiões. O principal conjunto de testes inclui algumas das imagens usadas por Oliveira *et al.* (2017). No entanto, a estratégia de detecção de anomalias difere significativamente - Oliveira *et al.* (2017) utilizou características SIFT e SVM para classificar cada região como normal ou anômala, enquanto neste trabalho as anomalias são segmentadas usando uma rede de reconstrução profunda. Além disso, Oliveira *et al.* (2017) usaram aprendizado supervisionado, com anomalias sendo artificialmente criadas pela colocação de pequenos fragmentos de imagens extraídos de outras amostras, enquanto o modelo aqui proposto é de uma única classe, sendo treinado apenas em amostras normais.

2.5 CONSIDERAÇÕES

Esse trabalho tem como objetivo a detecção de anomalias em imagens de PCIs, na busca por métodos para atingir esse objetivo, foi realizado um levantamento da literatura, focando especialmente em estudos que abordam a detecção e segmentação de anomalias em PCIs, bem como em técnicas de detecção de anomalias em imagens em geral. Os métodos de detecção de anomalias utilizados em imagens se resumem em técnicas de classificação, reconstrução e similaridade de características. De forma geral, a escolha desses métodos está intrinsecamente ligada à disponibilidade e natureza dos dados específicos do problema a ser abordado. Já as técnicas utilizadas em cada método dependem do seu objetivo final. Para a classificação, as técnicas são supervisionadas ou semi-supervisionadas, e as amostras são separadas em classes. Essas técnicas podem ser utilizadas para determinar se uma imagem contém ou não uma anomalia, sendo eficazes apenas quando se tem dados rotulados e em quantidade significativa para representar todas as situações. Os métodos de reconstrução têm como objetivo reconstruir imagens com anomalias de forma que elas se assemelhem o máximo possível às imagens normais, ou seja, sem anomalias. Isso permite a detecção de anomalias ao se comparar a imagem reconstruída com a imagem de entrada original. Já os métodos de similaridade de características usam vetores de características para criar modelos matemáticos ou estatísticos que descrevem a distribuição de dados. Esses modelos são então usados para identificar imagens ou regiões anômalas com base na diferença entre suas características e a distribuição normal. Por fim, há uma grande variedade de técnicas, como: Redes Neurais Profundas, *Autoencoders*, GAN, SVM,

entre outros.

Este trabalho de doutoramento foca na detecção de anomalias em imagens de PCIs através de técnicas de reconstrução. A revisão da literatura mostrou que, apesar de haver uma grande quantidade de trabalhos tratando de anomalias fora do contexto, há um crescimento significativo de trabalhos que abordam a detecção de anomalias sutis. Isso se deve, em parte, ao surgimento de bases de dados com imagens de objetos industriais, como a MVTEC-AD (BERGMANN *et al.*, 2019). Entretanto, mesmo nessas bases de dados há um controle maior de iluminação e posicionamento de objetos, e muitas aplicações no mundo real requerem o uso de modelos que funcionem também em ambientes com pouco ou nenhum controle de iluminação e posicionamento. Assim, muitas das técnicas propostas na literatura podem não ser capazes de detectar essas anomalias. Além disso, os trabalhos voltados para inspeção de PCIs focam os esforços na detecção de anomalias em PCI sem a montagem dos componentes. Dessa forma, a pesquisa realizada neste doutoramento contribui não apenas para o âmbito acadêmico, mas também para diversos segmentos industriais, ou aplicações de cunho social, como a inspeção de PCI em busca de fraudes que causem prejuízos ao poder público ou consumidores.

3 MATERIAL E MÉTODOS

Neste capítulo são apresentados os materiais e métodos utilizados nos experimentos deste trabalho. Primeiramente é apresentada uma definição matemática do problema, delimitando os pontos a serem abordados neste trabalho. Em seguida, são mostradas as bases de imagens utilizadas no experimentos, e também os procedimentos para a coleta dos dados. Também são detalhadas a arquitetura e os AEs utilizados nos experimentos, e os parâmetros de treinamento, como: função de ativação, função custo e método de aumento de dados aplicado nas imagens. Por fim, são detalhados os métodos de comparação utilizados na detecção das anomalias, através da comparação entre entrada e saída reconstruída.

3.1 DEFINIÇÃO DO PROBLEMA

Neste trabalho, é tratado o problema de detecção de anomalias em imagens de placas de circuito impresso. Consideramos que as anomalias podem ser sutis e estar inseridas em regiões de amostras normais, ou seja, essas anomalias podem ser pequenas em relação ao tamanho total da imagem, o que pode ser um desafio para algumas técnicas. Além disso, as imagens foram capturadas em ambientes não-controlados, ou seja, sem controle de posição ou iluminação. É importante ressaltar que este trabalho é uma continuação do que foi proposto por Oliveira *et al.* (2017). No entanto, a abordagem apresentada difere significativamente, pois foi adotada uma abordagem de um classe baseada em reconstrução utilizando *Autoencoders*, enquanto na proposta de Oliveira *et al.* (2017) a detecção é realizada através de classificação, com amostras de anomalias sendo geradas artificialmente. Acredita-se que métodos de reconstrução propiciam uma detecção visual das anomalias, o que pode ser mais eficiente que técnicas baseadas em classificação ou pontuação, pois as técnicas de reconstrução aprendem a extrair as próprias características durante o treinamento (MASCI *et al.*, 2011). Além disso, os métodos de reconstrução podem apontar exatamente onde estão as anomalias, possibilitando sua segmentação, diferente de alguns métodos que apontam apenas possíveis regiões que contêm anomalias.

Como os dados utilizados se tratam de imagens que contêm centenas ou milhares de *pixels*, pode-se afirmar que esses *pixels* estão de alguma forma relacionados e dependem uns dos outros para formarem estruturas na imagem. As anomalias são consideradas estruturas complexas, por serem formadas por diversos *pixels*, que formam um elemento qualquer que

originalmente não faz parte da PCI, e.g.: circuito integrado, resistor ou fio *jumper*. Assim, essas anomalias são consideradas coletivas, visto que um único *pixel* não pode ser considerado uma anomalia, mas sim o conjunto de *pixels* que formam o elemento eletrônico estranho que acaba interferindo no funcionamento da PCI, alterando seu propósito original.

As anomalias de alguma forma modificam o funcionamento das PCIs, fazendo com que elas não cumpram o objetivo para o qual foram projetadas, ou ainda com resultados que possam representar alguma fraude. Considerando que PCIs com anomalias são de difícil obtenção, e que seria necessário um grande esforço para simular anomalias, além da inviabilidade de se obter amostras representativas do universo completo de possíveis anomalias, o problema é tratado como abordagem de uma classe, i.e. o modelo é treinado apenas com imagens de instâncias normais.

3.2 DEFINIÇÃO MATEMÁTICA

O problema pode ser formulado da seguinte maneira: considere-se um espaço χ que engloba todas as instâncias contidas no universo do problema, abrangendo tanto as instâncias normais quanto anômalas, espaço este que representa todas as imagens de um determinado tamanho de $M \times N$ *pixels*. O conjunto de instâncias normais pode ser definido como $X \subseteq \chi$. A partir de um conjunto de treinamento $S \subseteq X$ o melhor modelo possível é representado por $h_S(x) : \chi \rightarrow \{0,1\}$, onde $h_S(x) = 1 \Leftrightarrow x \in X$.

Para controlar a assertividade de um modelo que busca se aproximar do ideal, pode-se utilizar uma função de custo $n_S(x) : \chi \rightarrow \mathbb{R}$, na qual valores maiores indicam instâncias mais prováveis de pertencerem a X . Uma vez a função de custo definida, um modelo mais preciso pode ser definido através de um limiar de anomalias T , conforme a Equação 1.

$$h_S(x) = \begin{cases} 1 & n_S(x) \geq T \\ 0 & n_S(x) < T \end{cases} \quad (1)$$

A função $n_S(x)$ pode ser o erro de reconstrução utilizado nos AEs ou até mesmo outro tipo de função que avalie a saída de forma a gerar uma mapa de anomalias, ou uma máscara que identifique as regiões que constituem uma anomalia. A única premissa fundamental que essa função deve atender é a capacidade de comparar a saída com a entrada, ou a entrada com informações provenientes do espaço latente. Quando devidamente treinado com amostras normais, o modelo não será capaz de reconstruir as anomalias contidas na imagem, mas apenas a


imagem sem anomalias, o que o torna uma ferramenta eficaz para a detecção dessas anomalias.

3.3 BASE DE IMAGENS MPI-PCB

A base de imagens utilizada neste trabalho é a MPI-PCB, a qual foi construída com a mesma PCI utilizada por (OLIVEIRA *et al.*, 2017). A base de dados contém 1742 imagens com dimensões de 4096×2816 *pixels* de uma PCI de bombas de combustível sem anomalias. As imagens foram capturadas usando uma câmera Canon EOS 1100D com lentes de 18-55mm. Também foram coletadas 55 imagens mostrando a PCI contendo modificações manualmente inseridas, com o objetivo de representar situações similares às aquelas encontradas em fraudes dessas PCIs. A Figura 6 mostra as anomalias contidas nas imagens de teste. Como o objetivo do trabalho é utilizar o aprendizado através de apenas uma classe, as imagens contendo modificações não foram utilizadas no processo de treinamento, somente para testes. Além das imagens coletadas com modificações, através da rotulagem das imagens, foram geradas manualmente as máscaras que correspondem à segmentação das modificações presentes na PCI. As máscaras tornam possível a avaliação mais precisa da segmentação da técnica proposta neste trabalho, e dos métodos da literatura avaliados. A Figura 7 mostra uma imagem da PCI e sua respectiva máscara. É importante destacar que uma das contribuições deste trabalho é a disponibilização pública da base de dados e as máscaras rotuladas, para que a base de imagens possa ser objeto de estudo em trabalhos futuros relacionados.

A PCI contida nas imagens possui apenas componentes com montagem *through-hole* (THT), sendo eles: resistores, conectores, capacitores e circuitos integrados. As imagens foram capturadas com a câmera tendo uma visão superior da PCI, sem restrições de posição ou iluminação. Além das variações na intensidade da luz em diferentes direções, a placa foi submetida a mudanças de perspectiva, alcançadas por meio da alteração tridimensional da posição da PCI em relação à câmera. Essas variações de posicionamento tornam o problema mais complexo, pois uma grande variedade de distorções e ruídos aparecem em alguns componentes e regiões. Outra consequência das mudanças de posicionamento é a falta de foco de algumas regiões, deixando-as com aspecto borrado. As variações também geraram sombras em algumas áreas, aumentando ainda mais a complexidade do problema. Alguns graus de distorção, variação de iluminação e até mesmo ruído são esperados, porém imagens com maior nitidez e melhores condições de iluminação tendem a influenciar o desempenho das técnicas de visão computacional. Em resoluções menores, as placas tendem a perder ainda mais qualidade na detecção, visto que

Figura 6 – Imagem da PCI destacando as anomalias contidas na base de imagens. Algumas são de fácil identificação, enquanto outras requerem uma maior atenção e experiência para serem identificadas. As modificações consistem na adição de pequenos circuitos integrados e fios jumpers.




Fonte: Autoria própria.

algumas modificações podem ficar imperceptíveis devido ao ruído.

3.3.1 Alinhamento das imagens

Observa-se que não há uma relação entre a posição de um *pixel* em uma imagem e uma mesma região em outras as imagens, ou seja, um mesmo elemento da PCI pode estar presente em diferentes regiões dependendo da imagem. A Figura 8 mostra alguns exemplos da base de imagens MPI-PCB, pode se observar que um componente pode estar em qualquer região da imagem dependendo dos ângulos de captura. Para minimizar esse problema, as imagens passaram por um processo de alinhamento, com o objetivo de alinhar todas as imagens em um mesmo plano. Essa prática é comum em outros tipos de aplicação em visão computacional, como é o caso de aplicações relacionadas a reconhecimento ou classificação de expressões faciais. A


Figura 7 – Imagem da PCI e sua respectiva máscara para a comparação de métodos de segmentação de anomalias.



Fonte: Autoria própria.

técnica empregada é clássica e foi utilizada por (OLIVEIRA *et al.*, 2017), onde o alinhamento é feito através de uma imagem de referência. Essa referência mostra a placa eletrônica totalmente visível, em boas condições de iluminação, com poucas distorções e pouco ruído.

Figura 8 – Comparação de imagens da base MPI-PCB, demonstrando a necessidade do alinhamento.




Fonte: Autoria própria.

O alinhamento é realizado através de um método de extração de características. Características em diversas regiões esparsas são detectadas e descritas usando a técnica SIFT (LOWE, 2004). Ao detectar as características similares em uma imagem a ser alinhada, a distância

Euclidiana em relação à imagem de referência é calculada no espaço das características SIFT. As similaridades encontradas são então filtradas utilizando o algoritmo RANSAC (FISCHLER; BOLLES, 1981). Esse algoritmo produz uma matriz que descreve uma projeção de plano para plano. Essa projeção permite colocar as imagens desalinhadas em uma perspectiva aproximada da imagem de referência. A Figura 9 demonstra o alinhamento de uma imagem da base de dados MPI-PCB.

Figura 9 – Comparação da imagem de uma PCI antes e após alinhamento utilizando SIFT e algoritmo RANSAC.



(a) Imagem original

(b) Imagem pós alinhamento

Fonte: Autoria própria.

Mesmo colocando as imagens em um mesmo plano de perspectiva, algumas distorções de posição e aspecto podem aparecer, principalmente em capacitores, circuitos integrados, e componentes de maior altura. A Figura 10 mostra as distorções sofridas pelos mesmos componentes em variadas imagens após o processo de alinhamento. Isso acontece porque o alinhamento da superfície da placa não leva em conta o fato de que esses componentes são objetos tridimensionais. Mesmo que eles estejam próximos da superfície da placa, as mudanças de perspectiva fazem com que diferentes partes destes componentes apareçam ou fiquem ocultas, além de ocultar partes da superfície da placa. O processo de alinhamento não é perfeito, e algumas variações sempre são esperadas. Isto quer dizer que, após o alinhamento, existe uma relação entre a posição de um *pixel* na imagem e a região da placa, mas uma mesma posição em imagens diferentes pode mostrar objetos que, embora próximos na placa, são distintos. Esse é um problema esperado e que torna o problema de detecção de anomalias ainda mais desafiador, pois torna necessário encontrar um modelo que seja capaz de detectar a perspectiva da imagem, e assim reconstruir todos os elementos com precisão.

Figura 10 – Exemplo de variação de distorções de aparência apresentadas em uma mesma região após o procedimento de alinhamento das imagens.



Fonte: Autoria própria.


3.3.2 Particionamento das imagens

Após a aquisição das imagens e o alinhamento descrito na seção anterior, as imagens foram particionadas, através da divisão da imagem em várias imagens de menores dimensões. Como as imagens coletadas têm alta resolução e contêm uma grande variedade de estruturas e características a serem analisadas, um único modelo para realizar essa tarefa exigiria uma grande quantidade de imagens e um modelo muito complexo, devido às dimensões de entrada (GOODFELLOW *et al.*, 2016). O simples redimensionamento das imagens poderia acarretar em componentes ou modificações muito pequenos na imagem, o que poderia afetar significativamente o desempenho do método proposto. Dessa forma, o particionamento foi utilizado para a redução de requisitos computacionais e de memória, sem a perda de informação a respeito dos componentes da placa. Regiões menores dividem o problema em problemas menores, e permitem que as anomalias sejam identificadas localmente, e não apenas com a classificação da imagem da placa em classes normal ou anomalia, como realizado em trabalhos da literatura como (OLIVEIRA *et al.*, 2017).

As imagens de entrada dos *Autoencoders* convolucionais foram particionadas em ima-

gens menores de dimensões 1024×1024 . As imagens foram divididas nessas dimensões para evitar um número excessivo de regiões, sem deixar de manter uma boa resolução mesmo para objetos menores contidos nas imagens. Como 2816 não é divisível por 1024, algumas regiões apresentam uma região sobreposta. Ainda nestas dimensões, seriam necessários *Autoencoders* com um número alto de parâmetros, portanto com um alto requisito de recursos computacionais e memória. Dessa forma, as regiões de 1024×1024 pixels após a extração foram redimensionadas para 256×256 pixels com o objetivo de reduzir ainda mais o tamanho da entrada, e conseqüentemente a necessidade de mais recursos computacionais, mas ainda mantendo os componentes e possíveis modificações claramente visíveis e com aspecto de tamanho original. A Figura 11 ilustra o processo de particionamento das imagens, mostrando cada região e seu respectivo identificador, e.g.: região 1_1, região 1_2, até a região 3_4.

Figura 11 – Particionamento realizado nas imagens das PCIs.



Fonte: Autoria própria.

Tabela 1 – Números da base de imagens MVTec-AD, sendo o número de imagens para as etapas de treinamento e teste, além do número de defeitos por categoria e a respectiva dimensão das imagens.

	Categoria	Nº treinamento	Nº teste (sem defeitos)	Nº teste (com defeitos)	Nº Grupo de defeitos	Dimensão da imagem
Texturas	Carpete	280	28	89	5	1024
	Grade	264	21	57	5	1024
	Couro	245	32	92	5	1024
	Azulejo	230	33	84	5	840
	Madeira	247	19	60	5	1024
Objetos	Garrafa	209	20	63	3	900
	Cabo	224	58	92	8	1024
	Cápsula	219	23	109	5	1000
	Noz	391	40	70	4	1024
	Porca de metal	220	22	93	4	700
	Pílula	267	26	141	7	800
	Parafuso	320	41	119	5	1024
	Escova de dentes	60	12	30	1	1024
	Transistor	213	60	40	4	1024
	Fecho de correr	240	32	119	7	1024
	Total	3629	467	1258	73	-

Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

3.4 BASE DE IMAGENS MVTEC-AD

A base de imagens MVTec-AD (BERGMANN *et al.*, 2019; BERGMANN *et al.*, 2021) é uma coleção de imagens industriais desenvolvida pela MVTec Software GmbH, uma empresa especializada em tecnologias de visão computacional. A base de imagens foi proposta com o objetivo de ser utilizada como *benchmark* para métodos de detecção de anomalias. Essa base de dados abrange uma variedade objetos e texturas, incluindo peças mecânicas, produtos eletrônicos, alimentos e tecidos. Composta por mais de cinco mil imagens de alta resolução, a MVTec-AD é dividida em quinze categorias distintas de objetos e texturas, sendo que cada categoria dispõe de um conjunto de imagens de treinamento sem defeitos ou modificações, e um conjunto de testes com vários tipos de defeitos diferentes, bem como imagens sem defeito. A Tabela 1 mostra a quantidade de imagens disponibilizada para as etapas de treinamento e teste, bem como o número de defeitos de cada categoria e a dimensão das imagens. As Figuras 12, 13, 14 e 15 mostram, respectivamente, as imagens das texturas e objetos contidos na base MVTec-AD.


Neste trabalho, a base MVTec-AD tem importância na avaliação da capacidade do método proposto de ser utilizado em outras tarefas de detecção e segmentação de anomalias. Pelo fato dessa base de imagens conter uma grande diversidade de objetos ou texturas, e seus respectivos defeitos, ela é um objeto interessante de estudo para determinar os pontos fortes e fracos do método. Além disso, como discutido no Capítulo 2, a MVTec-AD ganhou popularidade

Figura 12 – Um exemplo sem anomalias de cada textura presente na base de imagens MVTec-AD: carpete, grade, couro, azulejo e madeira.




Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

Figura 13 – Um exemplo com anomalias de cada textura presente na base de imagens MVTec-AD: carpete, grade, couro, azulejo e madeira.



Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

Figura 14 – Um exemplo sem anomalias de cada objeto presente na base de imagens MVTec-AD: garrafa, cabo, cápsula, noz, porca de metal, pílula, parafuso, escova de dentes, transistor e fecho de correr.




Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

recentemente em pesquisas voltadas para a detecção e segmentação de anomalias. Isso facilita a comparação direta do método proposto com diversas abordagens disponíveis na literatura, tornando-o um ponto de referência importante para a avaliação do desempenho do método em relação a outros métodos já estabelecidos.

3.5 ARQUITETURA DOS AUTOENCODERS

A arquitetura proposta para os AEs é formada de sete camadas, onde *encoder* e *decoder* são estruturalmente simétricos. Como ao longo da arquitetura são utilizadas camadas de convolu-

Figura 15 – Um exemplo com anomalias de cada objeto presente na base de imagens MVTEC-AD: garrafa, cabo, cápsula, noz, porca de metal, pílula, parafuso, escova de dentes, transistor e fecho de correr.



Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

ção e convolução transposta (ou deconvolução), a fim de, respectivamente, extrair características ou reconstruir elementos, a arquitetura utilizada pode ser caracterizada como um *Autoencoder* convolucional (AEC). Através das camadas convolucionais, o AEC comprime uma imagem de entrada em um vetor de baixa resolução chamado espaço latente, para então expandir ou decodificar este vetor para uma imagem com mesma dimensão da imagem de entrada. A função do *encoder* $z = g(y)$ recebe a entrada y e a comprime para o espaço latente z . A função do *decoder* $\hat{y} = f(z)$ resulta na reconstrução \hat{y} a partir do espaço latente z . Em resumo, a função de um AEC pode ser representada como $\hat{y} = f(g(y))$. Em um AEC ideal, a reconstrução \hat{y} seria idêntica à imagem de entrada y , ou seja, $y = \hat{y}$.

No método proposto, é treinado um AEC para cada região particionada da PCI, ou seja, para a PCI mostrada na Figura 11 são gerados 12 AECs distintos. Essas redes neurais foram treinadas exclusivamente com imagens de PCIs sem modificações, com isto devem ser capazes de reconstruir apenas este tipo de imagens. Quando um AEC treinado recebe imagens de PCIs que contêm modificações ou anomalias, o resultado esperado é uma reconstrução da imagem que não inclui essas modificações. Esse contraste entre a imagem de entrada com anomalia e a reconstrução gerada pelo AEC é essencial para a detecção de anomalias nas PCIs.

A Tabela 2 mostra as camadas e parâmetros utilizados ao longo da arquitetura do *Autoencoder*. Nessa arquitetura, tanto o *encoder* como o *decoder* são formados por sete camadas convolucionais ou de convolução transposta com filtros de tamanho 5×5 , passo 2×2 e preenchimento 0. O número de filtros em cada camada é mostrado na Tabela 2, começando em 32 e aumentando progressivamente até 256 conforme a profundidade da rede. A razão para

Tabela 2 – A arquitetura utilizada para o *Autoencoder* Convolutacional. Todas as camadas de convolução ou convolução transposta usam tamanho de filtros 5×5 , passo 2×2 e preenchimento 0.

Entrada: $y_{256 \times 256 \times 3}$
Conv(filtros=32); Normalização de lote; LeakyReLU
Conv(filtros=64); Normalização de lote; LeakyReLU
Conv(filtros=128); Normalização de lote; LeakyReLU
Conv(filtros=128); Normalização de lote; LeakyReLU
Conv(filtros=256); Normalização de lote; LeakyReLU
Conv(filtros=256); Normalização de lote; LeakyReLU
Conv(filtros=256); Normalização de lote; LeakyReLU
Totalmente conectadas (1024); Normalização de lote; Leaky ReLU
Totalmente conectadas (500); Leaky ReLU
Totalmente conectadas (1024); Normalização de lote; Leaky ReLU
TranspConv(filtros=256); Normalização de lote; LeakyReLU
TranspConv(filtros=256); Normalização de lote; LeakyReLU
TranspConv(filtros=128); Normalização de lote; LeakyReLU
TranspConv(filtros=128); Normalização de lote; LeakyReLU
TranspConv(filtros=64); Normalização de lote; LeakyReLU
TranspConv(filtros=32); Normalização de lote; LeakyReLU
TranspConv(filtros=3); Sigmoid
Saída: $\hat{y}_{256 \times 256 \times 3}$

Fonte: Autoria própria

aumentar o número de filtros nas camadas mais profundas da rede se deve ao fato de que, nas camadas iniciais, características primitivas são extraídas, enquanto nas camadas mais profundas, essas características são combinadas para formar características complexas (GOODFELLOW *et al.*, 2016). Quanto mais características primitivas são extraídas, maiores são as possibilidades de combinações para formar características complexas, justificando o aumento no número de filtros. Após experimentos iniciais, o espaço latente foi definido com 500 unidades. Essa escolha proporcionou melhores resultados, com menor custo de treinamento, uma vez que reduziu o número de sinapses na rede. Por fim, o *decoder* tem as mesmas camadas do *encoder*, mas essas camadas fazem o processo contrário (deconvolução), reconstruindo a imagem a partir do espaço latente.

Todas as camadas convolucionais são seguidas por uma camada de Normalização de lote (IOFFE; SZEGEDY, 2015). Com a normalização a rede se torna menos sensível ao ajuste de hiper-parâmetros, podendo se utilizar taxas de aprendizado mais altas, resultando no treinamento mais rápido (IOFFE; SZEGEDY, 2015). Em alguns casos, a Normalização de lotes também adiciona um certo grau de ruídos nos dados, o que auxilia na regularização da rede neural (IOFFE; SZEGEDY, 2015). A normalização de lotes de um vetor $Z^{(i)}$ é definida por $Z_{norm}^{(i)}$ na Equação 2, sendo μ e σ , respectivamente, a média e desvio padrão de $Z^{(i)}$, e ε é uma constante de estabilidade numérica.

$$Z_{norm}^{(i)} = \frac{Z^{(i)} - \mu}{\sqrt{\sigma^2 - \varepsilon}} \quad (2)$$

Com exceção da camada de saída, todas as outras camadas utilizam a função de ativação LeakyReLU (MAAS *et al.*, 2013; XU *et al.*, 2015). Essa função de ativação tem vantagens sobre a função de Unidade Linear Retificada (ReLU), dada sua capacidade de evitar unidades mortas. A função ReLU tende a fixar valores de unidades em 0 nas camadas mais profundas da rede, o que faz com que o modelo não utilize a informação dessas unidades durante o aprendizado. As unidades mortas fazem com que algumas informações de certas regiões sejam perdidas (XU *et al.*, 2015). Já a função LeakyReLU adiciona pequenos “declives” na função ReLU quando os valores são negativos. A Equação 3 mostra a função de ativação *ReLU*, enquanto a Equação 4 expressa a função *LeakyReLU*. Sendo o valor de $\alpha = 0,2$ o utilizado na arquitetura proposta.

$$f(x) = \max(0, x) \quad (3)$$


$$f(x) = \begin{cases} x & \text{se } x \geq 0 \\ \alpha x & \text{se } x < 0 \end{cases} \quad (4)$$

Na camada de saída, a função de ativação utilizada foi a sigmoide. A saída dessa função permite apenas valores entre 0 e 1. Como as imagens utilizadas são de 8 bits, os valores dos *pixels* variam entre 0 e 255 e foram normalizados, a função sigmoide se mostra mais coerente para essa camada, visto que a função tem limites superior e inferior (i.e. 0 e 1). Usar uma função com *LeakyReLU* na saída pode aumentar o erro de reconstrução, visto que os valores máximos e mínimos dos *pixels* não serão os mesmos para todas as imagens. Dessa forma, valores intermediários poderiam sofrer disparidades quando forem normalizados para o intervalo de 0 e 1.

Durante o treinamento, as imagens de entrada foram modificadas com a inclusão aleatória de áreas retangulares em cor preta. *Autoencoders* treinados para eliminar ruído utilizam esse tipo de estratégia para a rede aprender a eliminar diversos tipos de ruído. Essa estratégia foi utilizada neste trabalho com o objetivo de aumentar a regularização da rede, reduzindo o super-ajuste dos parâmetros. Os retângulos podem simular a oclusão de alguns elementos na imagem, forçando o modelo, durante o treinamento, a levar em consideração mais elementos da imagem para extrair características. Isso auxilia na regularização e generalização do problema, contribuindo para reconstruções mais eficazes. Esse processo de aumento de dados é conhecido

como *Cutout* aleatório (DEVRIES; TAYLOR, 2017). A Figura 16 ilustra o processo de *Cutout* realizado durante o treinamento.

Figura 16 – Processo de *Cutout* gerado durante o treinamento. Os retângulos pretos inseridos na imagem funcionam como uma estratégia de regularização.



Fonte: Autoria própria.

3.6 FUNÇÃO DE CUSTO

As funções de custo mais utilizadas no treinamento de *Autoencoders* são as funções baseadas em informações de *pixels*, como o Erro Quadrático Médio (EQM). Porém, esse tipo de função assume que não há uma correlação entre os vários *pixels* contidos em uma imagem. No entanto, imagens costumam apresentar estruturas formadas pela relação entre uma vizinhança de *pixels*, o que dificilmente é capturado por funções como o EQM. Funções desse tipo aplicadas em *Autoencoders* frequentemente resultam em saídas borradas quando usadas para a reconstrução de imagens. Por essas razões, neste trabalho foi utilizado a mescla do EQM com a função de custo de conteúdo para o treinamento do AEC.

A função de custo de conteúdo foi introduzida por (JOHNSON *et al.*, 2016). Ela identifica a diferença entre duas imagens baseada em características de alto nível extraídas de redes neurais pré-treinadas. Essa função já foi utilizada em aplicações como: transferência de estilo (JOHNSON *et al.*, 2016), super-resolução (JOHNSON *et al.*, 2016; RAD *et al.*, 2019) e restauração de imagens (YEH *et al.*, 2017; YU *et al.*, 2018). As características são extraídas de redes pré-treinadas em grandes base de imagens utilizadas para aplicações generalistas. As aplicações generalistas se caracterizam em tentar resolver problemas amplos, como classificação de imagens em centenas ou milhares de classes, o que permite que as redes neurais aprendam a extrair diversas características diferentes que podem ser úteis para outros domínios de problemas.

Um exemplo clássico, é o treinamento de redes neurais com a base de dados ImageNet (DENG *et al.*, 2009a), um desafio de classificação que pode conter mais de mil classes como saída. Neste trabalho, foi utilizada a rede de classificação VGG19 (SIMONYAN; ZISSERMAN, 2014), pré-treinada com a base de dados ImageNet. Essa arquitetura foi escolhida por ser amplamente utilizada em outros trabalhos que fazem uso da função de custo de conteúdo, devido as características robustas que a rede fornece. Utilizando as características de alto nível, a função encoraja o AEC a reconstruir imagens com representações das características similares às da imagem de entrada, fazendo com que o *Autoencoder* aprenda com mais informações do que puramente *pixels* sem correlação.

Seja $\phi_j(y)$ o resultado da ativação da camada j de uma rede pré-treinada ϕ , onde a imagem y é processada. Sendo que j é uma camada convolucional, $\phi_j(y)$ deve resultar em um saída de tamanho $C_j \times H_j \times W_j$, onde C_j é o número de filtros, e $H_j \times W_j$ são as dimensões de saída de cada filtro da camada j . A função de custo de conteúdo é a distância quadrática normalizada da representação das características da reconstrução \hat{y} e a imagem de referência y , conforme é mostrado na Equação 5.

$$l_{feat}^{\phi,j}(\hat{y}, y) = \frac{1}{C_j H_j W_j} \|\phi_j(\hat{y}) - \phi_j(y)\|_2^2 \quad (5)$$

$$EQM(y, \hat{y}) = \frac{1}{nm} \sum_n \sum_m^{i=1, j=1} (y_{i,j} - \hat{y}_{i,j})^2 \quad (6)$$

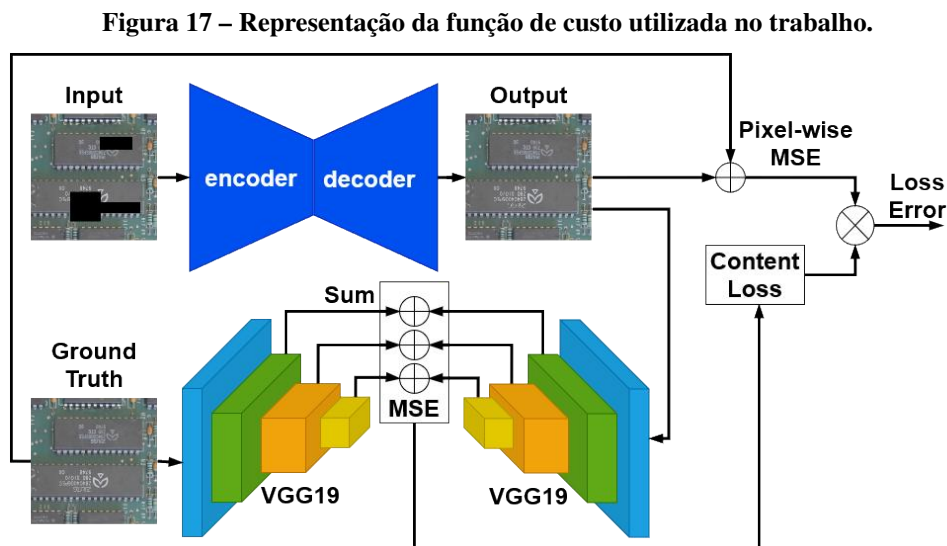
No processo de treinamento usando a função de custo de conteúdo, o objetivo é minimizar o erro de reconstrução entre as imagens de entrada, representadas por y , e as imagens reconstruídas, representadas por \hat{y} , usando camadas mais iniciais da rede pré-treinada ϕ . Um AEC treinado para a reconstrução com essa função de custo tende a produzir imagens reconstruídas que se assemelham a y em termos de conteúdo da imagem e estruturas espaciais (JOHNSON *et al.*, 2016). Neste trabalho, foi utilizada a soma das diferenças das camadas 5, 8, 13 e 15 da arquitetura VGG19. A escolha foi baseada em experimentos empíricos iniciais para melhorar a qualidade das reconstruções e, conseqüentemente, a capacidade do modelo de detecção de anomalias.

A função de custo de conteúdo controla a reconstrução de estruturas maiores e detalhes, mas tende a ter problemas na reconstrução de texturas. Por essa razão, essa função de custo foi combinada com o EQM, conforme demonstra a Equação 7, onde λ_1 e λ_2 são os pesos

que definem a contribuição de cada função de custo. Eles foram definidos empiricamente em $\lambda_1 = 0.01$ e $\lambda_2 = 1$.

$$\mathcal{L}_{rec} = \lambda_1 \mathcal{L}_{EQM} + \lambda_2 \mathcal{L}_{feat} \quad (7)$$

A Figura 17 ilustra o cálculo da função de custo definida. A imagem original é utilizada como referência, sendo que a entrada da rede é a imagem de referência modificada através do processo de *Cutout*. A comparação é então realizada entre a imagem de entrada e a reconstrução gerada pelo AEC através das características extraídas da VGG19, juntamente com o erro quadrático médio entre as duas imagens. Ressalta-se que esta forma de combinar a função de custo de conteúdo com o erro quadrático médio para o treinamento de um *Autoencoder* é uma das contribuições deste trabalho.

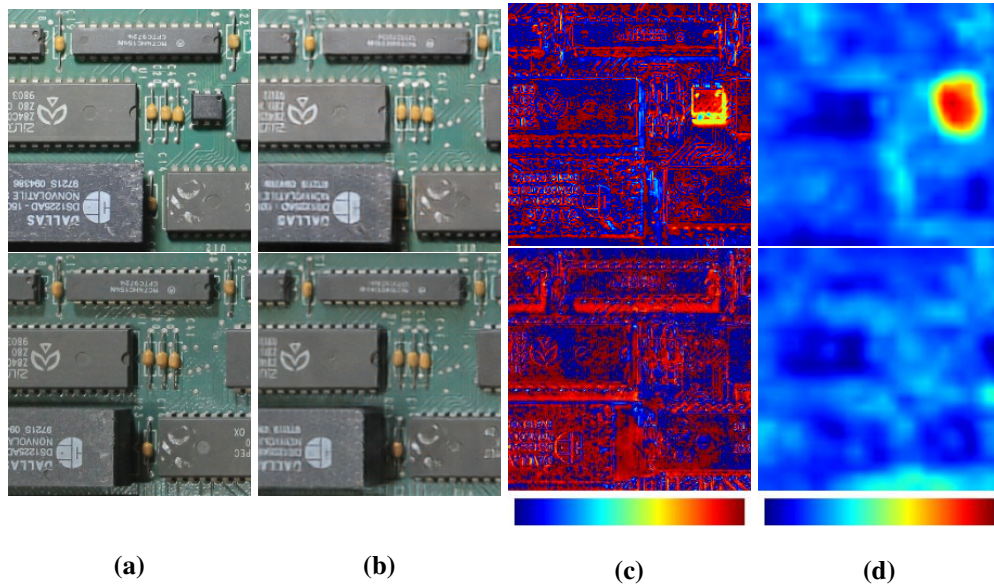


Fonte: Autoria própria.

3.7 SEGMENTAÇÃO DE ANOMALIAS

Após o treinamento, o *Autoencoder* foi utilizado para segmentar anomalias comparando a imagem reconstruída com a imagem de entrada. Em um cenário ideal, onde o *Autoencoder* é perfeito para a tarefa proposta, uma comparação simples, como a diferença absoluta entre *pixels*, poderia ser um método eficaz para a segmentação das anomalias. No entanto, imagens em situações reais têm pequenas distorções de perspectiva, ruídos, e variações de iluminação que podem afetar a reconstrução de alguma forma. Essas variações podem causar pequenas imperfeições ao longo dos contornos, ou em regiões contendo sombras e reflexos na imagem

Figura 18 – (a) Imagem de entrada de uma PCI com modificações (superior) e sem modificações (inferior), (b) imagem de reconstrução do AEC, (c) diferença absoluta entre *pixels* entre a imagem de entrada e a reconstrução, e (d) método proposto para a segmentação de anomalias usando a diferença perceptiva. A diferença absoluta entre *pixels* tem altos valores mesmo em regiões sem diferenças visuais. Já no método proposto as regiões caracterizadas por anomalias são claras e bem definidas.



Fonte: Autoria própria

reconstruída. Nesses casos, funções baseadas apenas na diferença entre os *pixels* podem resultar em um grande número de regiões que são falsos positivos. A Figura 18(c) ilustra um exemplo do uso da diferença absoluta entre *pixels* da imagem de entrada e a imagem reconstruída de uma PCI, incluindo um caso em que há modificações, e outro sem modificações. Pode-se notar que a diferença absoluta entre *pixels* produz um resultado em que há valores altos de diferença em muitas regiões em que as diferenças não são visíveis a olho nu.

Para superar as dificuldades citadas, a função de comparação proposta utiliza os mesmos conceitos da função de custo de conteúdo. Em vez de se basear em comparações de *pixels*, a comparação é realizada usando características de alto nível que incorporam informações de vizinhanças de *pixels* e estruturas visíveis da imagem. Com este tipo de abordagem, pequenas modificações que aparecem apenas em *pixels* isoladamente podem passar despercebidas. No entanto, a robustez do método é superior, visto que as modificações nas PCIs são formadas por estruturas e regiões da imagem com aglomerados de *pixels*, desde que a imagem possua resolução suficientemente alta. Assim como na função de custo, o método proposto utiliza uma rede com arquitetura VGG19, que foi treinada para classificação de imagens na base de dados ImageNet. A rede é utilizada para extrair as características de alto nível da imagem de entrada y e da sua reconstrução \hat{y} gerada pelo AEC. As características são então comparadas através

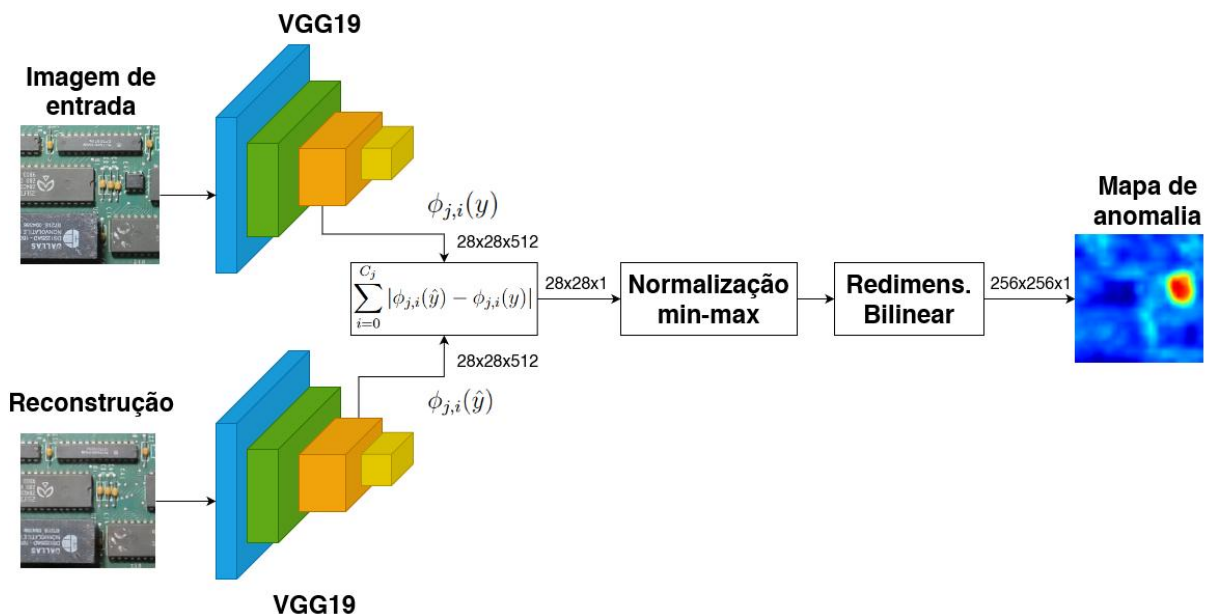
da diferença absoluta entre as características (ou ativações) da camada ϕ da VGG19, conforme expressado na Equação 8.

$$\mathcal{A}(\hat{y}, y) = \sum_{i=0}^{C_j} |\phi_{j,i}(\hat{y}) - \phi_{j,i}(y)| \quad (8)$$

onde C_j é o número de filtros de saída da camada j . \mathcal{A} é a matriz de *pixels* que representa o mapa de anomalias, e ele tem as mesmas dimensões $H_j \times W_j$ de saída da camada ϕ_j . Em experimentos iniciais, a camada 12 da VGG19 mostrou os melhores resultados para a segmentação de anomalias, com 512 filtros de dimensões 28×28 .

Para se obter o mapa de anomalias que é usado para a segmentação, é realizada a normalização min-max dos valores usando todas as imagens do conjunto de testes. Esse conjunto deve conter exemplos de imagens contendo anomalias, para que no momento da normalização seja possível obter os valores de magnitude produzido por modificações. Sem exemplos de modificações, o processo de normalização pode não ser eficaz, pois o maior valor da diferença absoluta entre os mapas de características corresponderia a uma modificação real, levando a uma possível maior incidência de falsos positivos. Portanto, a normalização é uma etapa essencial e requer ao menos uma imagem que apresente modificações para seu correto funcionamento.

Figura 19 – Diagrama de funcionamento das etapas de geração do mapa de anomalias do método proposto.



Fonte: Autoria própria.

Após a normalização o mapa de anomalias terá as mesmas dimensões dos filtros de saída da camada ϕ_j . Para que a anomalia seja segmentada com precisão, o mapa de anomalias é

redimensionado para as mesmas dimensões da imagem de entrada (256×256 pixels). Com esse mapa de anomalias, é possível então gerar uma máscara através da definição de um limiar T . O limiar pode ser ajustado conforme a necessidade de um sistema mais ou menos rigoroso na segmentação e detecção das modificações, então sua definição correta também é um ponto de atenção na avaliação de desempenho do método proposto.

A Figura 19 mostra exemplos da segmentação de anomalias através da soma da diferença absoluta entre os pixels e o método de segmentação proposto. A imagem apresenta um mapa de calor para facilitar a visualização, no qual as regiões em cores frias têm menor probabilidade de serem modificações, e regiões em cores quentes maior probabilidade. Para o método proposto, pode-se observar como as diferenças em regiões sem modificações são menos perceptíveis ao usar a diferença absoluta entre pixels, portanto em cor azul. Já para as regiões contendo modificações, as diferenças são significativamente maiores que em outras regiões, demonstrado pelas cores mais quentes. Consideramos que o uso da diferença perceptiva para segmentar as anomalias comparando-se uma imagem de entrada com a sua reconstrução é uma das contribuições originais deste trabalho.

3.8 DISCUSSÃO

Neste capítulo, foi explorada a importância da função de custo na formação de *Autoencoders* (AEC), destacando as limitações do uso de funções convencionais baseadas em informações de pixels, como o Erro Quadrático Médio (EQM). Observa-se que em imagens as relações entre pixels vizinhos frequentemente formam estruturas complexas e significativas, não são usualmente capturadas por funções de custo que consideram apenas pixels independentes. Foi introduzida a função de custo de conteúdo, inspirada no trabalho de Johnson *et al.* (2016), que utiliza características de alto nível extraídas de uma rede pré-treinada, neste caso, a VGG19. Essa abordagem proporciona ao AEC uma compreensão mais profunda das características estruturais e de conteúdo das imagens, superando algumas limitações das funções de custo tradicionais. A combinação do EQM com a função de custo de conteúdo apresenta uma abordagem híbrida, buscando benefícios de ambas as funções. Este método de treinamento proporciona ao AEC a capacidade de reconstruir imagens mantendo não apenas a fidelidade aos pixels, preservando estruturas e relações espaciais importantes dos objetos.

Foi proposto um método, que em vez de utilizar a diferença absoluta entre pixels, extrai as características de alto nível de uma rede VGG19 para formar um mapa de anomalias. Este

mapa fornece uma representação mais robusta das discrepâncias entre a imagem original e sua reconstrução, levando a uma segmentação mais confiável de regiões anômalas.

A metodologia proposta neste capítulo visa abordar os desafios específicos associados à detecção de anomalias em imagens, fornecendo uma base conceitual para compreender o desenvolvimento e a implementação do método proposto. No próximo capítulo, são abordados os experimentos realizados para avaliar o desempenho do modelo proposto e discutidos os resultados obtidos.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os experimentos conduzidos para a validação do método proposto para detecção e segmentação de anomalias. Além da avaliação do método em si, é realizada uma comparação com métodos da literatura sobre a base de imagens MPI-PCB proposta neste trabalho, e sobre a base de imagens MVTec-AD, amplamente utilizada na literatura. O código utilizado nos experimentos foi implementado na linguagem Python, usando as bibliotecas Tensorflow ¹ e OpenCV², sendo os experimentos realizados na plataforma Google Colab ³. O código fonte dos experimentos pode ser acessado através do seguinte repositório: https://github.com/Diulhio/pcb_anomaly/.

4.1 MÉTODOS COMPARATIVOS

De acordo com a revisão bibliográfica realizada, nenhum estudo anterior aborda especificamente a segmentação de anomalias baseada em imagens em PCIs montadas. Como mencionado anteriormente no Capítulo 2, os estudos encontrados se concentram na inspeção de PCIs sem a montagem de componentes, ou utilizam técnicas supervisionadas de visão computacional para determinar se anomalias estão presentes em regiões da imagem, sem realizar a segmentação em si. Tais abordagens não tornam justa a comparação direta com o método proposto neste trabalho, dada a diferença de foco ou a saída gerada pelos métodos. Portanto, os métodos da literatura utilizados para a comparação com o método proposto são focados em tarefas generalistas de segmentação de anomalias, em particular aqueles que apresentam resultados promissores na base de imagens MVTec-AD. O método proposto neste trabalho pode ser comparado de forma direta com tais métodos, visto que todos utilizam a mesma estratégia de treinamento de uma classe, e produzem máscaras para a segmentação de anomalias como saída. A seleção dos métodos comparativos foi baseada em sua relevância na literatura, bem como a disponibilidade de código fonte oficial que fosse capaz de ser executado na infraestrutura disponível para a pesquisa. Os métodos comparativos também foram selecionados seguindo o levantamento da literatura realizado (Capítulo 2), sendo selecionados tanto métodos de reconstrução quanto similaridade de características.

¹ www.tensorflow.org

² opencv.org

³ colab.research.google.com

No momento da realização dos experimentos, o método PaDiM (DEFARD *et al.*, 2021) apresentava os resultados considerados como estado da arte para a segmentação de anomalias com o MVTec-AD. Este é um método de similaridade de características que apresentou resultados promissores utilizando características extraídas da arquitetura *Wide ResNet-50-2* (ZAGORUYKO; KOMODAKIS, 2016). Entretanto, devido a altos requisitos de memória do método, os experimentos com esse método foram realizados com características extraídas de uma arquitetura *ResNet18* (HE *et al.*, 2016). Outros métodos de similaridade de características avaliados foram o SPTM (WANG *et al.*, 2021a) e SPADE (COHEN; HOSHEN, 2020). Também foi selecionado o DFR (SHI *et al.*, 2021), um método de reconstrução que utiliza características extraídas de uma arquitetura VGG19 como entrada de um *Autoencoder* convolucional. Recentemente, um *framework* reunindo diversas técnicas da literatura foi proposto por Akcay *et al.* (2022). Esse *framework* contém algumas das técnicas utilizadas como métodos comparativos neste trabalho, bem como técnicas desenvolvidas posteriormente à realização dos experimentos reportados neste capítulo.

4.2 MÉTRICAS DE AVALIAÇÃO

Para a avaliação do método proposto e dos métodos comparativos, foram selecionadas métricas que avaliam a segmentação das anomalias a nível de pixel, sendo as métricas: *Intersection over the Union* (IoU), e área abaixo da curva ROC, bem como Precisão, *Recall* e *F-Score* para o melhor limiar identificado. Também foi avaliada a capacidade de detecção de anomalias dos métodos, enquanto a segmentação considera as informações a nível da classificação de cada pixel, a detecção apenas expressa se há uma anomalia na imagem ou não. Para evitar a interferência de pequenos ruídos na classificação, foi considerado que uma anomalia existe em uma imagem se a segmentação contiver ao menos dez *pixels* que representam anomalias. Todas as métricas utilizadas, sejam elas a nível de segmentação ou detecção, foram computadas através da contagem dos Verdadeiro Positivos (VP), Verdadeiro Negativos (VN), Falso Positivos (FP), e Falso Negativos (FN).

A precisão indica a proporção de *pixels* detectados corretamente. Quando a precisão se aproxima de 1.0, isso indica que há poucas detecções incorretas ou pixels erroneamente classificados como positivos. Por outro lado, o *recall* (ou também Taxa de Verdadeiro Positivos (TVP)) indica a proporção de detecções ou *pixels* que eram esperados que foram realmente detectados, sendo que um *recall* com valor 1.0 indica que a maioria das anomalias foram

detectadas. De forma geral, a precisão, conforme mostra a Equação 9, expressa a relação de predições corretas da classe positiva com o total de predições da classe positiva. Já o *recall*, conforme mostra a Equação 10, expressa a relação das predições corretas da classe positiva com todas as instâncias conhecidas da classe positiva. Já o *F-Score*, demonstrado na Equação 11, representa a média harmônica das métricas Precisão e *Recall*.

$$Precisao = \frac{VP}{VP + FP} \quad (9)$$

$$Recall \text{ ou } TVP = \frac{VP}{VP + FN} \quad (10)$$

$$F\text{-score} = \frac{2 * (Recall * Precisao)}{(Recall + Precisao)} \quad (11)$$

A Área abaixo da curva ROC (ROC-AUC) é uma métrica amplamente utilizada na avaliação de métodos de segmentação de anomalia, sendo usualmente utilizada em trabalhos que utilizam a base de imagens MVTec-AD como objeto de estudos (BERGMANN *et al.*, 2019; COHEN; HOSHEN, 2020; BERGMANN *et al.*, 2021; DEFARD *et al.*, 2021; WANG *et al.*, 2021a; SHI *et al.*, 2021). Essa métrica demonstra o quão eficaz um modelo ou técnica é para balancear as taxas de verdadeiros e falso positivos, considerando a aplicação de diferentes limiares de decisão. Em outras palavras, ela mede a capacidade de uma técnica de segmentar as regiões como anomalias de forma correta, evitando a detecção de regiões que não contêm anomalias. A ROC-AUC é calculada como a área normalizada sob uma curva ROC, a qual é gerada através de uma representação gráfica da taxa de verdadeiros positivos (TVP ou *Recall*) em função da Taxa de Falso Positivos (TFP), enquanto os limiares de classificação do modelo variam. As Equações 10 e 12 apresentam, respectivamente, as taxas de verdadeiros e falsos positivos.

$$TFP = \frac{FP}{FP + VN} \quad (12)$$

O IoU, ou índice de Jaccard, é outra métrica amplamente utilizada em diversos trabalhos de segmentação semântica, e desafios como o *Common Objects in Context (COCO)*⁴. Para a avaliação de técnicas de segmentação, essa métrica expressa a similaridade entre duas formas, quantificando a sobreposição entre a máscara conhecida da anomalia e o mapa de anomalia gerado pela segmentação. O IoU é expresso pela Equação 13.

⁴ Common Objects in Context – <http://cocodataset.org>.

$$IoU = \frac{VP}{(VP + FN + FP)} \quad (13)$$

Os valores de IoU reportados nos experimentos representam o mais alto valor de IoU conforme a variação do limiar de classificação. Em comparação com a ROC-AUC, o IoU é mais sensível à variação do formato das regiões segmentadas. Isto significa que caso haja diferentes tipos de anomalias com variados tamanhos, um erro de classificação de um pixel em anomalias menores terá um impacto maior que um erro de classificação em uma anomalia maior.

4.3 SELEÇÃO DO LIMIAR DE CLASSIFICAÇÃO

A seleção do limiar de classificação T foi necessária para a quantificação de algumas das métricas de avaliação definidas. Para a identificação do melhor valor T possível para o balanceamento da taxa de verdadeiros e falsos positivos, foi aplicada a média geométrica máxima (G-mean) entre tais taxas. A Equação 14 apresenta a média geométrica máxima para um limiar T_i .

$$\text{G-mean}_{T_i} = \sqrt{TV P_{T_i} * (1 - TFP_{T_i})} \quad (14)$$

Esse método é amplamente utilizado em aplicações de Aprendizado de Máquina para a definição de limiares de classificação, especialmente em problemas onde há um grande desbalanceamento entre as classes. De forma geral, o limiar definido pela média geométrica máxima pode ser visto como o ponto de limiar na curva ROC que mais se aproxima do canto superior esquerdo, o qual corresponde ao limiar mais próximo de um classificador que não cometeu nenhum erro de predição.

4.4 PROCEDIMENTO DE TREINAMENTO

A metodologia utilizada no treinamento do método proposto segue as informações contidas no Capítulo 3. Conforme descrito, as imagens contidas na base MPI-PCB foram alinhadas, devido à grande variabilidade de posicionamento, e particionadas, dado a resolução e dimensões de componentes e anomalias presentes nas imagens. Para esta base de imagens, há um total de 1742 imagens de PCIs sem modificações, e 55 imagens de PCIs contendo modificações. No treinamento e teste do modelo proposto, as imagens sem modificações foram redivididas, sendo 55 destas imagens destinadas aleatoriamente para teste, e 1687 imagens para treinamento e

validação. Este foi o número de imagens selecionadas para haver uma equiparação com o número de imagens contendo anomalias, facilitando assim a interpretação dos resultados, resultando em um total de 110 imagens para testes. Já para o treinamento do método, 10% das imagens, portanto 169, foram destinadas para validação, enquanto 1518 imagens foram destinadas para treinamento.

Para o treinamento da base de imagens MVTEC-AD foi mantida a divisão originalmente proposta pelo autor (BERGMANN *et al.*, 2019), sendo que há diferentes números de imagens para cada objeto ou textura. O número exato de imagens pode ser consultado na Seção 3.4. De forma geral, as classes de objetos e texturas têm um número aproximado de 250 imagens dedicadas para o treinamento. Para o treinamento dessa base de imagens, foi mantida a proporção de 90% das imagens sem objetos contendo modificações para treinamento e 10% para validação. Já as imagens de teste são as mesmas originalmente selecionadas pelos autores (BERGMANN *et al.*, 2019).

Dada a grande variabilidade de distorções de perspectiva, mas o limitado número de instâncias para treinamento, técnicas para o aumento de dados foram empregadas durante o treinamento. Para a base MPI-PCB foram aplicados os aumentos de dados: translação, rotação, distorção (ou *shear*), saturação, contraste, brilho, escala (ou *zoom*) e *cutout* (DEVRIES; TAYLOR, 2017). Os aumentos de translação, rotação, distorção e escala buscam simular os efeitos e variações gerados pelo processo de alinhamento, onde podem haver pequenas variações de posição das regiões. Os aumentos de dados de saturação, contraste e brilho, buscam simular variações de iluminação durante a captura das imagens das PCIs. Já o *cutout* adiciona retângulos variados em várias regiões da imagem para simular um comportamento similar ao uso de *dropout*. Isso faz com que a rede não foque a atenção na reconstrução de nenhuma região da imagem em especial, aumentando sua capacidade de generalização da reconstrução. A Tabela 3 mostra as faixas de valores e as probabilidades utilizadas para o aumento de dados, sendo esse aumento feito *online*, ou seja, durante o treinamento as imagens sofreram alterações aleatórias e então foram submetidas ao *Autoencoder*. Para o treinamento da base de imagens MVTEC-AD foram utilizados de forma aleatória os aumentos de dados: rotação, distorção (ou *shear*), saturação, contraste, brilho, escala e *cutout*. As faixas de valores e as probabilidades utilizadas para o treinamento do MVTEC-AD são as mesmas definidas na Tabela 3.

O treinamento da arquitetura especificada na Seção 3.5 foi realizado com os mesmos hiper-parâmetros para as duas bases de imagens avaliadas. O tamanho dos lotes (*batches*) foi


Tabela 3 – Probabilidades e faixas de valores utilizados para o aumento de dados *online*.

Efeito de aumento	Probabilidade de ocorrer	Valor mínimo	Valor máximo
Translação	100%	0 <i>pixels</i>	80 <i>pixels</i>
Rotação	80%	-5°	+5°
Distorção	80%	-2	+2
Saturação	60%	0.7	1.3
Contraste	60%	0.8	1.2
Brilho	60%	0.9	1.1
Escala	80%	90%	99%
<i>Cutout</i>	100%	0 retângulos dimensão mínima 10	15 retângulos dimensão máxima 80

Fonte: Autoria própria

definido como 128, e o treinamento ocorreu ao longo de 1000 épocas. Utilizou-se o otimizador Adam (KINGMA; BA, 2014) com uma taxa de aprendizado que segue um padrão de decaimento cosseno com uma fase inicial de aquecimento. A taxa de aprendizado começou em 1×10^{-5} , aumentou para 0,0072 após três épocas e, em seguida, diminuiu novamente para 1×10^{-5} seguindo uma função cosseno. O Gráfico 1 demonstra a curva de decaimento utilizada. Essa curva de decaimento impede que o otimizador caia em mínimos locais, levando o treinamento para melhores soluções.

Gráfico 1 – Taxa de aprendizado usada durante o treinamento com otimizador Adam.



Fonte: Autoria própria

4.5 RESULTADOS NA BASE MPI-PCB

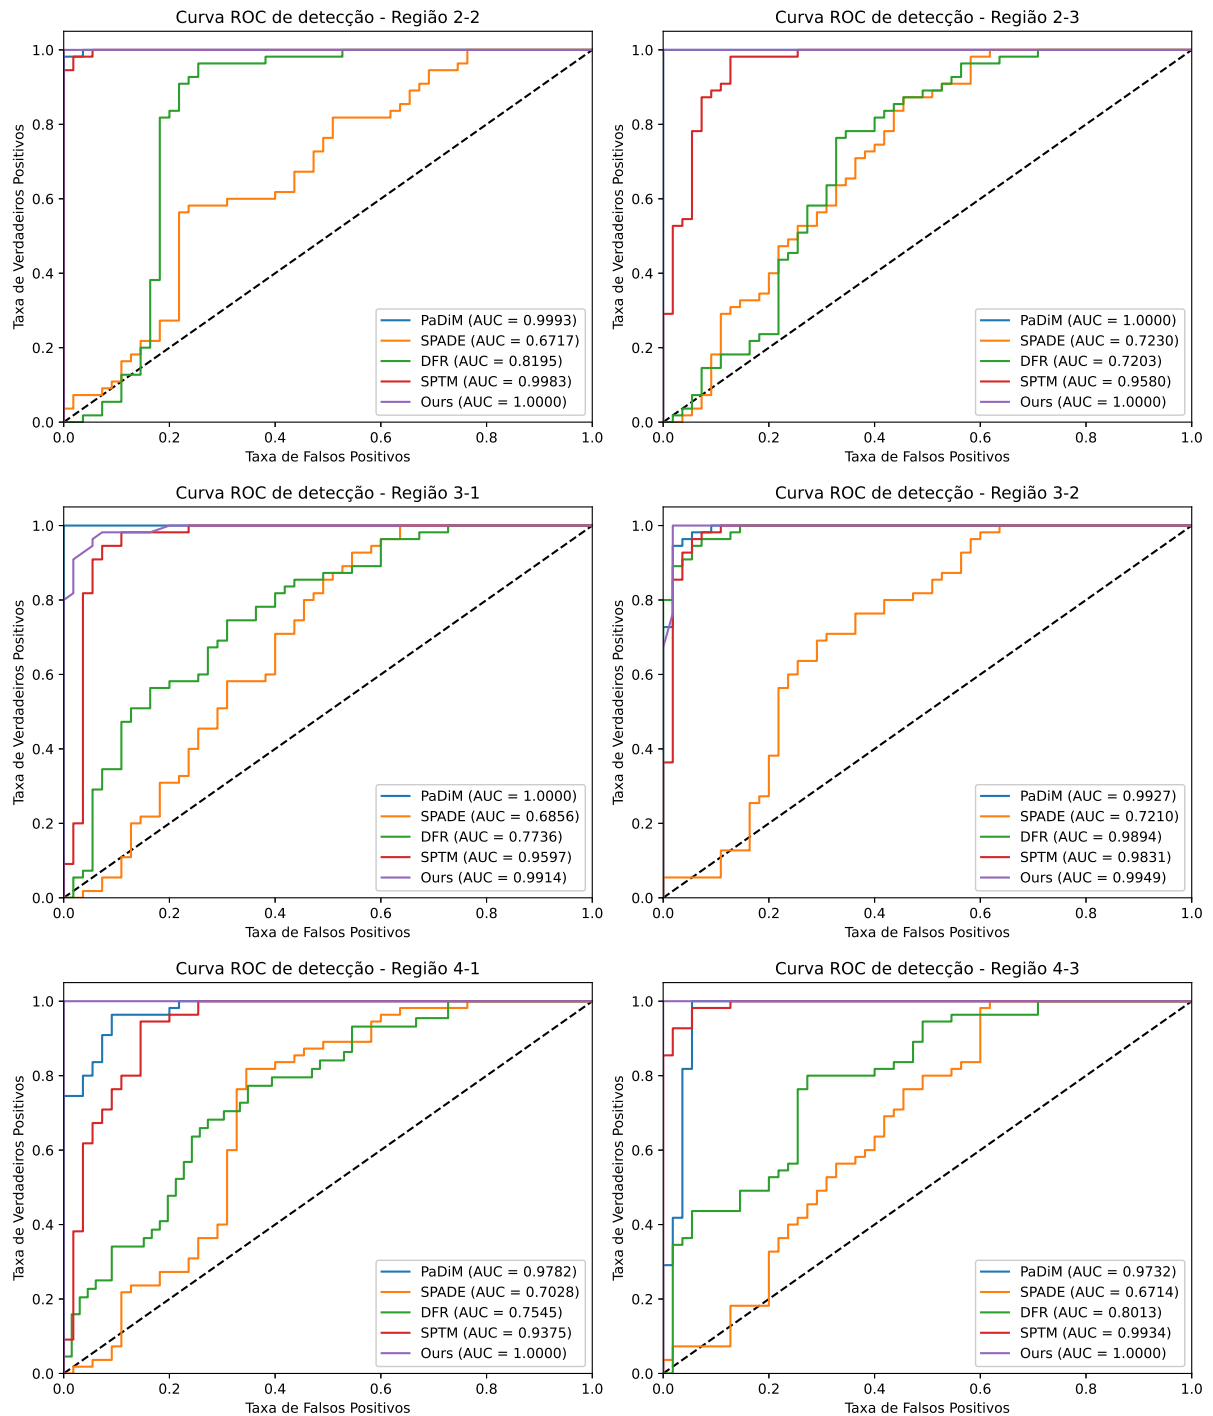
Para a avaliação do desempenho do *Autoencoder* proposto e dos métodos comparativos, foi primeiro utilizado o conjunto de testes do MPI-PCB. Conforme apresentado na Seção 3.3.2, as imagens contidas na base de imagens foram particionadas, a fim de proporcionar melhor resolução das imagens para o reconhecimento das anomalias. Como não há anomalias em todas as regiões da imagem, foram selecionadas apenas as 6 regiões que contêm qualquer presença de modificações. A seleção das regiões é necessária, porque conforme especificado na Seção 3.7 o método de segmentação proposto requer ao menos uma imagem contendo PCIs com modificações para a normalização dos valores do mapa de anomalias. Essas regiões contêm modificações inseridas de forma artificial, que simulam modificações reais inseridas em possíveis situações de fraude. As modificações foram criadas através da solda de componentes junto dos componentes já presentes nas placas, sendo as principais modificações encontradas a inserção de circuitos integrados e fios *jumper*. Para mais detalhes das modificações contidas nas placas, consultar a Seção 3.3. A avaliação dos métodos foi realizada com as 110 amostras do conjunto de testes, sendo 55 amostras contendo PCIs com modificações e 55 amostras sem modificações.

Tabela 4 – Resultados do método proposto e dos métodos comparativos para a base de imagens MPI-PCB. Os resultados são mostrados apenas nas regiões que contêm ao menos uma modificação no conjunto de testes. Os números das regiões representam as colunas e linhas da imagem particionada (para mais detalhes ver a Figura 11). Valores maiores indicam os melhores desempenhos, sendo que para precisão, *recall* e *F-score* os resultados são para o limiar que apresentou maior *G-mean*.

Métrica	Método	reg. 2×2	reg. 2×3	reg. 3×1	reg. 3×2	reg. 4×1	reg. 4×3	Média
IoU	Proposto	0,755	0,664	0,608	0,525	0,778	0,732	0,677
	PaDiM	0,603	0,624	0,489	0,145	0,656	0,524	0,507
	SPADE	0,319	0,272	0,419	0,353	0,457	0,474	0,382
	DFR	0,297	0,098	0,117	0,386	0,196	0,190	0,214
	SPTM	0,505	0,428	0,447	0,314	0,240	0,502	0,406
Precisão de Segment.	Proposto	0,858	0,752	0,767	0,643	0,849	0,840	0,785
	PaDiM	0,732	0,742	0,594	0,240	0,765	0,687	0,627
	SPADE	0,364	0,301	0,621	0,417	0,526	0,533	0,460
	DFR	0,246	0,078	0,117	0,419	0,141	0,221	0,204
Sensibil. de Segment.	SPTM	0,601	0,577	0,457	0,410	0,300	0,627	0,495
	Proposto	0,876	0,858	0,758	0,747	0,915	0,856	0,835
	PaDiM	0,856	0,851	0,826	0,413	0,896	0,744	0,764
	SPADE	0,754	0,754	0,572	0,715	0,793	0,833	0,737
F-Score de Segment.	DFR	0,687	0,491	0,310	0,691	0,347	0,407	0,489
	SPTM	0,760	0,853	0,668	0,643	0,395	0,760	0,680
	Proposto	0,863	0,805	0,769	0,688	0,889	0,851	0,811
	PaDiM	0,785	0,791	0,691	0,307	0,829	0,714	0,686
F-Score de Segment.	SPADE	0,489	0,436	0,597	0,521	0,632	0,645	0,553
	DFR	0,357	0,136	0,163	0,511	0,209	0,283	0,275
	SPTM	0,676	0,687	0,533	0,492	0,347	0,680	0,569

Fonte: Autoria própria.

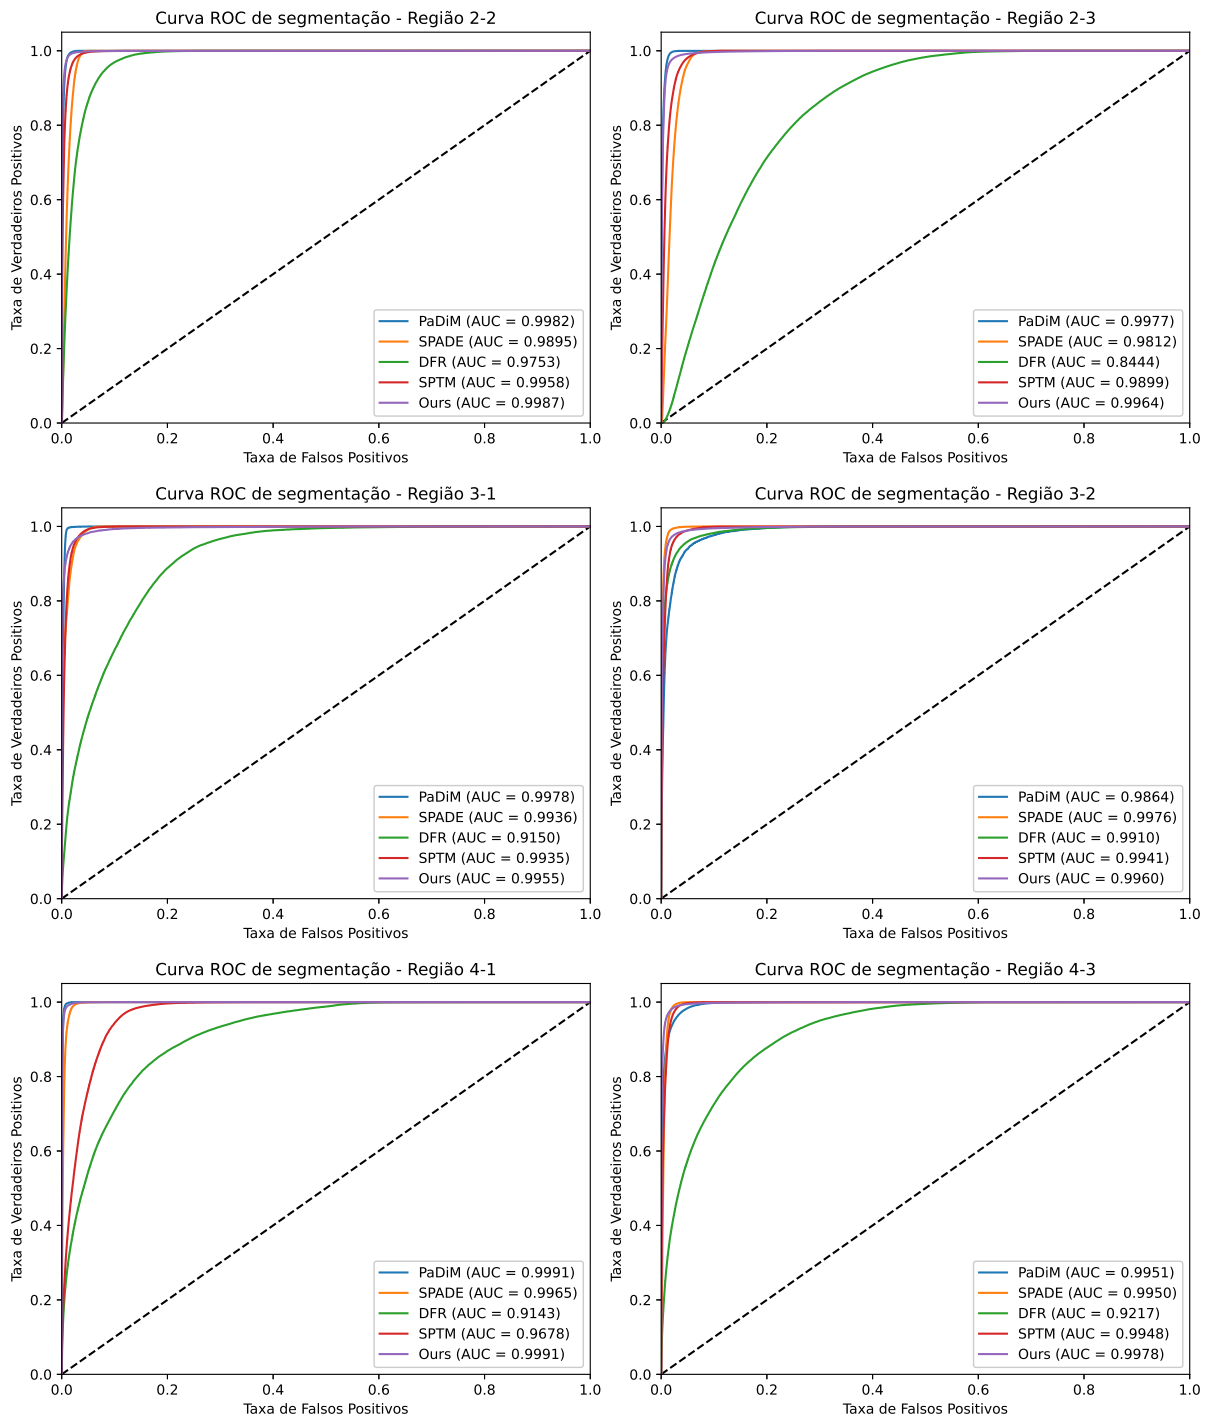
Gráfico 2 – Curvas ROC para a detecção de anomalias de cada uma das regiões avaliadas. O número das regiões indica a coluna e linha que representa cada região na imagem particionada (ver Figura 11).



Fonte: Autoria própria

Os Gráficos 2 e 3, e a Tabela 4 mostram os resultados obtidos para os métodos avaliados em cada região contendo modificações. Os valores destacados em **negrito** indicam os melhores resultados para cada uma das métricas. De forma geral, os resultados demonstraram que o método proposto supera, ou pelo menos tem desempenho similar ao dos métodos comparativos

Gráfico 3 – Curvas ROC para a segmentação de anomalias de cada uma das regiões avaliadas. O número das regiões indica a coluna e linha que representa cada região na imagem particionada (ver Figura 11).



Fonte: Autoria própria

da literatura, os quais têm os resultados que representam o estado da arte para a base de imagens MVTEC-AD.

A detecção simples de modificações, onde a saída é apenas um valor binário que

especifica se há ou não modificações em uma região têm os resultados apresentados no Gráfico 2. Como mostrado nos gráficos, os resultados obtidos pelos métodos proposto, PaDiM e SPTM, foram similares na maioria dos casos avaliados. No entanto, o método proposto demonstrou ser particularmente eficaz, alcançando ROC-AUC 1.0 em 4 das 6 regiões avaliadas, o que significa que todas as anomalias foram detectadas sem falsos positivos, bem como anomalias não foram detectadas nas amostras que não contêm modificações. Já os outros métodos, SPADE e DFR, apresentaram resultados significativamente inferiores, conforme as curvas ROC demonstram, é difícil definir um limiar com balanceamento entre TVP e TFP para essas técnicas.

Para a segmentação de anomalias (Gráfico 3), os resultados obtidos pelos métodos avaliados foram notavelmente elevados, com todos os métodos alcançando ROC-AUC superior a 0,9 para praticamente todas as regiões analisadas. Esses resultados evidenciam a capacidade desses métodos de segmentar corretamente a maioria das anomalias. Entre os métodos avaliados, o método proposto e PaDiM apresentaram o melhor desempenho médio. A desproporção de classes é um fator importante a ser considerado na avaliação da segmentação de anomalias. Isso explica a diferença entre os resultados de ROC-AUC de detecção e segmentação para os métodos SPADE e DFR na detecção e segmentação. O conjunto de testes é balanceado para detecção, pois contém o mesmo número de amostras positivas e negativas. No entanto, as classes são muito desequilibradas para a segmentação por pixel, com menos de 2% sendo *pixels* positivos. Isso permite que o modelo gere pequenos erros de segmentação em várias imagens sem afetar significativamente o ROC-AUC de segmentação, mas com um alto impacto no ROC-AUC de detecção.

Embora os resultados de ROC-AUC obtidos pelo método proposto e PaDiM sejam similares, observa-se que a segmentação em várias amostras é visivelmente diferente. Isso se dá devido ao desequilíbrio entre *pixels* positivos e negativos, o que leva a valores ROC-AUC altos mesmo quando o modelo produz classificações de falsos positivos. A IoU pode ser uma métrica mais adequada para expressar a precisão da segmentação, pois é mais sensível a *pixels* classificados incorretamente e, conseqüentemente, a desvios na forma e tamanho dos objetos segmentados. Esse comportamento pode ser observado na Figura 20, que apresenta algumas amostras de segmentação produzidas pelo método proposto e os métodos comparativos. É possível observar que a maioria dos métodos comparativos apresentou vários falsos positivos, ou seja, esses métodos conseguiram localizar com sucesso as modificações de maneira geral, no entanto, foram detectados vários *pixels* adicionais, fazendo com que a forma segmentada

não corresponda totalmente à anomalia. Em geral, os modelos identificam grandes regiões ao redor das modificações ou formas menores que não cobrem todo um componente. Isso pode ser interpretado como uma detecção falsa por um inspetor humano sem conhecimento especializado, pois cobre não apenas um componente, mas uma região que inclui partes de outros componentes. Esse tipo de segmentação pode fazer com que a confiança do humano no sistema seja prejudicada. Adicionalmente, a Figura 20 mostra que alguns métodos comparativos podem produzir mais detecções de falsos positivos quando não há anomalias na placa, o que não acontece no método proposto.

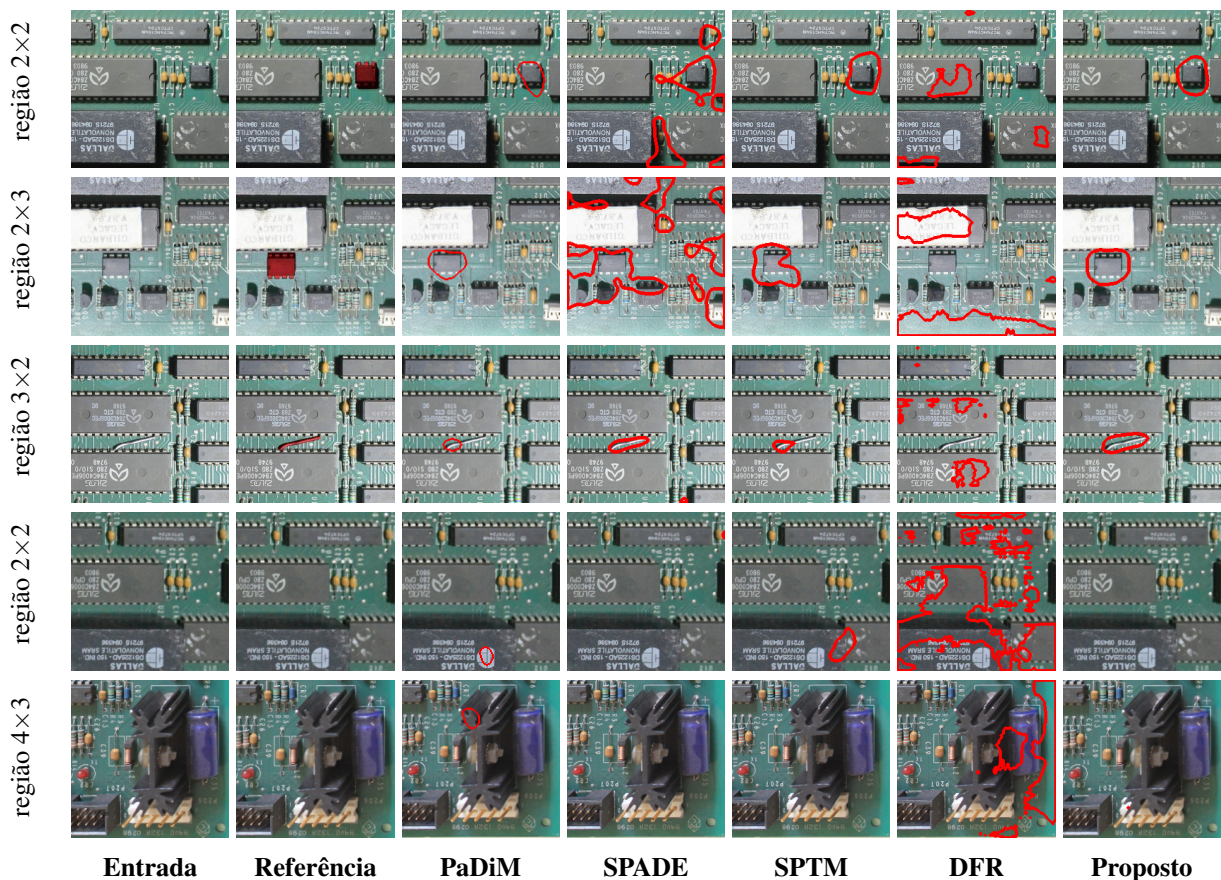


Figura 20 – Comparação da segmentação de anomalias do método proposto e os métodos comparativos, as imagens das regiões 3×2, 2×3 e 2×2 contêm PCIs contendo modificações, enquanto as imagens das regiões 2×2 and 4×3 contêm PCIs sem modificações. Os contornos vermelhos representam as anomalias detectadas pelos algoritmos ou métodos avaliados.

Com relação à medida IoU, observa-se que o método proposto superou os métodos comparativos para todas as regiões avaliadas, alcançando um IoU superior a 0,5 para todas as regiões. Essa performance é particularmente relevante, já que desafios como Pascal VOC (EVERINGHAM *et al.*, 2010) e COCO (LIN *et al.*, 2014) utilizam $\text{IoU} > 0,5$ como um critério para detecção bem-sucedida. É importante destacar que a medida IoU é sensível ao tamanho das modificações, pois o peso de um pixel classificado incorretamente é maior para objetos menores.

O método proposto foi capaz de segmentar modificações pequenas, como o fio de ligação na região 3×2 (primeira linha da Figura 20). Já o PaDiM apresentou IoU próximo a 0,5 para todas as regiões, exceto para a região 3×2 , que contém a modificação de menor tamanho. Nessa região, houve um alto número de falsos negativos, o que resultou em uma segmentação parcial. Já os métodos SPADE, SPTM e DFR apresentaram desempenho inferior em vários casos, devido ao elevado número de falsos positivos. Como discutido anteriormente, essas técnicas acabam segmentando grandes regiões ao redor das modificações e detectando modificações onde elas não existem. As variações de iluminação e perspectiva presentes na base imagens podem explicar os resultados obtidos por essas técnicas.

A diferença na qualidade da segmentação entre as técnicas é reforçada ao se observar as métricas de precisão, *recall* e *F-score*. O método proposto apresentou a melhor precisão de segmentação para todas as regiões, o que significa que ele conseguiu detectar *pixels* que representam anomalias com menos falsos positivos. Ao mesmo tempo, em relação ao *recall* de segmentação, o método proposto supera os métodos comparativos para quase todas as regiões de maneira significativa, comprovando que o método proposto apresenta menos falsos negativos. As vantagens do método proposto são refletidas na média do *F-score*, que é significativamente maior do que a alcançada pelos métodos comparativos.

Em resumo, os resultados obtidos mostram que, embora todas as técnicas possam detectar e segmentar modificações (como indicado pelas métricas ROC-AUC de detecção e segmentação), o método proposto pode aproximar de forma mais precisa a forma dos objetos (como indicado pelo IoU, precisão, *recall* e *F-score*). Essa vantagem pode ajudar um inspetor humano a identificar os componentes específicos que caracterizam uma modificação em um cenário prático com uma maior certeza, tornando o processo de inspeção mais confiável.

4.6 RESULTADOS NA BASE DE IMAGENS MVEC-AD

Para avaliar o desempenho do método proposto para outros contextos de localização de anomalias, além das modificações de PCIs para as quais ele foi projetado, uma avaliação foi realizada utilizando-se do conjunto de imagens MVTec-AD. Neste experimento, o método proposto foi comparado com outros métodos comparativos, permitindo assim uma análise mais precisa de suas capacidades. Os resultados obtidos são apresentados através da curva ROC de detecção e segmentação, para todos os objetos e texturas, mostrados na Figura 21. Além disso, as métricas avaliadas são apresentadas nas Tabelas 5 e 6, seguindo a categorização definida

por (BERGMANN *et al.*, 2019), com anomalias agrupadas por tipo: “objetos” e “texturas”. A categoria “objetos” mostra certos tipos de objetos, onde a maioria das anomalias envolve a adição, remoção ou modificação de peças ou componentes, enquanto a categoria “texturas” apresenta ampliações de superfícies, onde as anomalias consistem em alterações em um padrão de textura comum.




Figura 21 – Curvas ROC de detecção e segmentação usando o método proposto para todas as texturas e objetos da base de imagens MVTec-AD. As linhas contínuas representam dados da categoria objetos, enquanto as linhas pontilhadas representam dados da categoria de texturas.

De acordo com as Tabelas 5 e 6, o método proposto obteve um desempenho competi-

Tabela 5 – Resultados obtidos com a base de imagens MVTec-AD para o método proposto e os métodos comparativos para a categoria de objetos.

Métrica	Método	Garrafa	Cabo	Cápsula	Noz	Porca de Metal	Pílula	Parafuso	Escova de dentes	Transistor	Fecho de correr	Média
Detecção ROC-AUC	Proposto	0,979	0,954	0,674	0,982	0,895	0,642	0,941	0,999	0,961	0,900	0,893
	PaDiM	0,996	0,855	0,870	0,841	0,974	0,869	0,745	0,947	0,925	0,741	0,876
	SPADE	0,972	0,795	0,897	0,881	0,710	0,801	0,667	0,889	0,903	0,966	0,848
	DFR	0,996	0,757	0,951	1,000	0,914	0,904	0,919	0,989	0,765	0,883	0,908
	SPTM	0,992	0,996	0,807	1,000	0,989	0,863	0,780	0,986	0,975	0,894	0,928
Segmentação ROC-AUC	Proposto	0,932	0,955	0,966	0,983	0,967	0,930	0,990	0,987	0,948	0,931	0,959
	PaDiM	0,981	0,958	0,982	0,979	0,967	0,947	0,972	0,987	0,968	0,982	0,972
	SPADE	0,970	0,905	0,984	0,985	0,971	0,950	0,991	0,988	0,866	0,986	0,960
	DFR	0,948	0,902	0,983	0,985	0,920	0,966	0,989	0,980	0,781	0,960	0,941
	SPTM	0,972	0,973	0,966	0,978	0,950	0,943	0,945	0,979	0,921	0,970	0,874
IoU	Proposto	0,499	0,348	0,239	0,536	0,617	0,265	0,359	0,522	0,503	0,386	0,427
	PaDiM	0,593	0,290	0,280	0,422	0,645	0,389	0,137	0,415	0,511	0,380	0,406
	SPADE	0,557	0,166	0,336	0,489	0,721	0,426	0,270	0,465	0,239	0,496	0,417
	DFR	0,398	0,186	0,300	0,446	0,344	0,251	0,266	0,286	0,173	0,407	0,306
	SPTM	0,516	0,439	0,222	0,378	0,595	0,436	0,105	0,384	0,423	0,322	0,382
Precisão de Segmentação	Proposto	0,690	0,460	0,330	0,680	0,720	0,370	0,510	0,630	0,710	0,520	0,562
	PaDiM	0,680	0,340	0,380	0,520	0,720	0,510	0,200	0,470	0,610	0,420	0,485
	SPADE	0,660	0,250	0,420	0,600	0,820	0,580	0,350	0,530	0,360	0,610	0,518
	DFR	0,540	0,150	0,460	0,610	0,700	0,660	0,370	0,420	0,380	0,520	0,481
	SPTM	0,560	0,530	0,130	0,400	0,630	0,500	0,070	0,480	0,540	0,060	0,390
Recall de Segmentação	Proposto	0,640	0,590	0,470	0,720	0,810	0,480	0,550	0,760	0,630	0,600	0,625
	PaDiM	0,830	0,660	0,520	0,680	0,860	0,630	0,310	0,790	0,770	0,720	0,677
	SPADE	0,780	0,340	0,640	0,720	0,860	0,610	0,530	0,780	0,410	0,730	0,640
	DFR	0,580	0,520	0,450	0,660	0,410	0,460	0,560	0,580	0,270	0,660	0,515
	SPTM	0,860	0,670	0,380	0,800	0,790	0,510	0,190	0,460	0,420	0,670	0,575
F-Score de Segmentação	Proposto	0,670	0,520	0,390	0,700	0,760	0,420	0,530	0,690	0,670	0,560	0,591
	PaDiM	0,740	0,450	0,440	0,590	0,780	0,560	0,240	0,590	0,680	0,530	0,560
	SPADE	0,720	0,280	0,500	0,660	0,840	0,600	0,430	0,630	0,390	0,660	0,571
	DFR	0,560	0,240	0,450	0,630	0,520	0,540	0,440	0,490	0,320	0,590	0,478
	SPTM	0,680	0,059	0,190	0,530	0,700	0,510	0,100	0,470	0,470	0,110	0,382

Tabela 6 – Resultados obtidos com a base de imagens MVTEC-AD para o método proposto e os métodos comparativos para as categorias de texturas.

Métrica	Método	Carpete	Grade	Couro	Azulejo	Madeira	Média
Detecção ROC-AUC	Proposto	0,888	0,776	0,808	0,914	0,947	0,866
	PaDiM	0,984	0,898	0,959	0,988	0,990	0,964
	SPADE	0,928	0,473	0,965	0,954	0,958	0,856
	DFR	0,976	0,781	0,915	0,991	0,987	0,930
	SPTM	0,999	0,910	0,984	1,000	0,987	0,976
Segmentação ROC-AUC	Proposto	0,954	0,938	0,652	0,983	0,856	0,876
	PaDiM	0,989	0,936	0,917	0,991	0,940	0,955
	SPADE	0,989	0,983	0,928	0,993	0,953	0,969
	DFR	0,984	0,740	0,900	0,993	0,954	0,914
	SPTM	0,988	0,978	0,926	0,989	0,926	0,961
IoU	Proposto	0,444	0,204	0,173	0,397	0,255	0,295
	PaDiM	0,470	0,204	0,375	0,290	0,311	0,330
	SPADE	0,498	0,293	0,413	0,355	0,354	0,383
	DFR	0,437	0,138	0,323	0,326	0,329	0,311
	SPTM	0,433	0,239	0,373	0,270	0,276	0,318
Precisão de Segmentação	Proposto	0,620	0,300	0,530	0,300	0,450	0,440
	PaDiM	0,560	0,330	0,340	0,440	0,370	0,408
	SPADE	0,590	0,400	0,410	0,470	0,430	0,460
	DFR	0,560	0,090	0,430	0,350	0,390	0,364
	SPTM	0,490	0,260	0,320	0,390	0,360	0,364
Recall de Segmentação	Proposto	0,610	0,400	0,610	0,300	0,370	0,458
	PaDiM	0,740	0,350	0,670	0,720	0,660	0,628
	SPADE	0,750	0,520	0,720	0,760	0,660	0,682
	DFR	0,720	0,240	0,650	0,710	0,750	0,614
	SPTM	0,690	0,440	0,540	0,840	0,480	0,598
F-Score de Segmentação	Proposto	0,610	0,340	0,570	0,300	0,410	0,446
	PaDiM	0,640	0,340	0,450	0,550	0,470	0,490
	SPADE	0,660	0,450	0,520	0,580	0,520	0,546
	DFR	0,630	0,130	0,520	0,470	0,510	0,452
	SPTM	0,570	0,330	0,400	0,530	0,410	0,448

tivo na categoria “objetos”, apresentando desempenho semelhante aos métodos comparativos, especialmente SPADE e PaDiM. Isso indica que o método pode apresentar melhores resultados para problemas em que a maioria das anomalias ou modificações são a adição ou remoção de objetos na área inspecionada. É importante ressaltar que, devido ao enfoque na representação de estruturas e organizações de *pixels*, o método pode ser especialmente eficaz em tarefas de detecção de anomalias em objetos complexos, onde a presença de pequenas modificações pode ser crucial para identificação de problemas. Além disso, é importante notar que os resultados variam entre objetos individuais dentro da mesma categoria. Isso indica que a capacidade de cada método de detectar anomalias pode depender das características intrínsecas do objeto em questão, ou até mesmo das anomalias presentes em cada objeto. O método proposto teve maiores dificuldades em identificar anomalias nos objetos “Cápsula” e “Pílula”. Em ambos os casos, algumas anomalias são na textura do objeto, outras estão relacionadas a pequenas variações de coloração, e outras na serigrafia presente. A Figura 22 mostra alguns exemplos de anomalias

para esses dois objetos. É importante notar que isso não é necessariamente uma desvantagem apenas do método proposto, visto que mesmo os métodos comparativos apresentam resultados inferiores em certos objetos, como por exemplo o SPADE com “Cabo”, “Porca de Metal” e “Parafuso”, ou ainda o PaDiM com “Parafuso” e “Fecho de correr”.

Figura 22 – Exemplos dos objetos Cápsula e Pílula da base MVTec-AD, onde o objeto da primeira imagem é livre de anomalia, e os outros são exemplos de anomalias variadas contidas na base de imagens.



Fonte: Bergmann *et al.* (2019), Bergmann *et al.* (2021)

Já para a subcategoria “texturas”, o método proposto não obteve o mesmo desempenho que os métodos comparativos. Esse comportamento pode ser explicado pela combinação da função de custo de conteúdo com o erro quadrático médio de *pixels*. Em outras tarefas que envolvem reconstrução de imagens, como a super-resolução (JOHNSON *et al.*, 2016), a perda de conteúdo geralmente é utilizada em conjunto com a função de “perda de estilo”, que tenta manter as distribuições de recursos em cada camada da rede neural iguais tanto na imagem original quanto na sua reconstrução. A perda de conteúdo é responsável por assegurar que as estruturas de imagem importantes sejam preservadas na reconstrução, enquanto o erro quadrático médio compara *pixels* individuais na imagem original e na sua reconstrução. Isso significa que o método proposto possui uma capacidade reduzida de representar padrões de textura gerais, sendo direcionado para representar estruturas e organizações de *pixels* observadas durante o treinamento. Por outro lado, isso permite que o método proposto detecte mesmo anomalias pequenas. O problema é agravado pelo pequeno número de amostras de treinamento no conjunto MVTec-AD, que possui apenas cerca de 250 imagens de treinamento por classe.

4.7 ESTUDOS DE ABLAÇÃO DA FUNÇÃO DE CUSTO

Para investigar a contribuição de cada componente da função de custo, foi realizado um estudo de ablação sobre os pesos das funções Erro Quadrático Médio e Perda Perceptual. Como a função de custo é o componente central do método proposto, esses experimentos são fundamentais para identificar suas vantagens e desvantagens em diferentes aplicações. Esses experimentos foram realizados em dois conjuntos de dados diferentes, o MPI-PCB e o MVTec-AD, avaliando os resultados qualitativos da reconstrução. O objetivo principal é identificar a combinação ideal de pesos dos componentes da função de custo que gerem imagens de reconstrução o mais visualmente similares possível à imagem de entrada. Foram utilizadas sete combinações diferentes de pesos de perda, variando entre 0, 1, 0.1 e 0.01, para avaliar a sensibilidade da performance do método em relação a esses pesos.

A Figura 23 apresenta os resultados da reconstrução de algumas regiões do conjunto de dados MPI-PCB, bem como objetos e texturas do conjunto de dados MVTec-AD. Esses resultados evidenciam a importância da perda de conteúdo para a qualidade da reconstrução. No caso das imagens do conjunto de dados MPI-PCB, é possível observar que a perda de conteúdo desempenha um papel fundamental na reconstrução de detalhes finos. Quando λ_2 é menor que λ_1 , o AEC é incapaz de reconstruir as trilhas da PCI. Além disso, com valores menores de λ_2 , os problemas conhecidos decorrentes da utilização exclusiva do EQM tornam-se mais evidentes, tais como imagens borradas e bordas irregulares. Por outro lado, o modelo treinado com apenas perda de conteúdo ($\lambda_1 = 0$ e $\lambda_2 = 1$) gera imagens com texturas irregulares, especialmente em regiões contendo pequenos componentes, como resistores ou terminais de circuitos integrados. A partir desses resultados, é possível afirmar que a combinação adequada das funções de perda é essencial para a obtenção de uma reconstrução de alta qualidade.

A contribuição da perda de conteúdo é mais evidente nas reconstruções das imagens do conjunto de dados MVTec-AD, devido ao fato de que esse conjunto de imagens possui menos dados disponíveis para treinamento. Com um peso maior na perda de conteúdo, o modelo é capaz de reconstruir melhor as imagens, com detalhes finos e bordas consistentes, já que a perda de conteúdo depende de outro modelo pré-treinado em um grande conjunto de dados. Além disso, em todas as combinações, a principal limitação da função de custo proposta é a dificuldade de reconstruir padrões de textura de maneira confiável, como pode ser observado nas reconstruções de carpete e avelã, onde todos os modelos avaliados apresentaram problemas

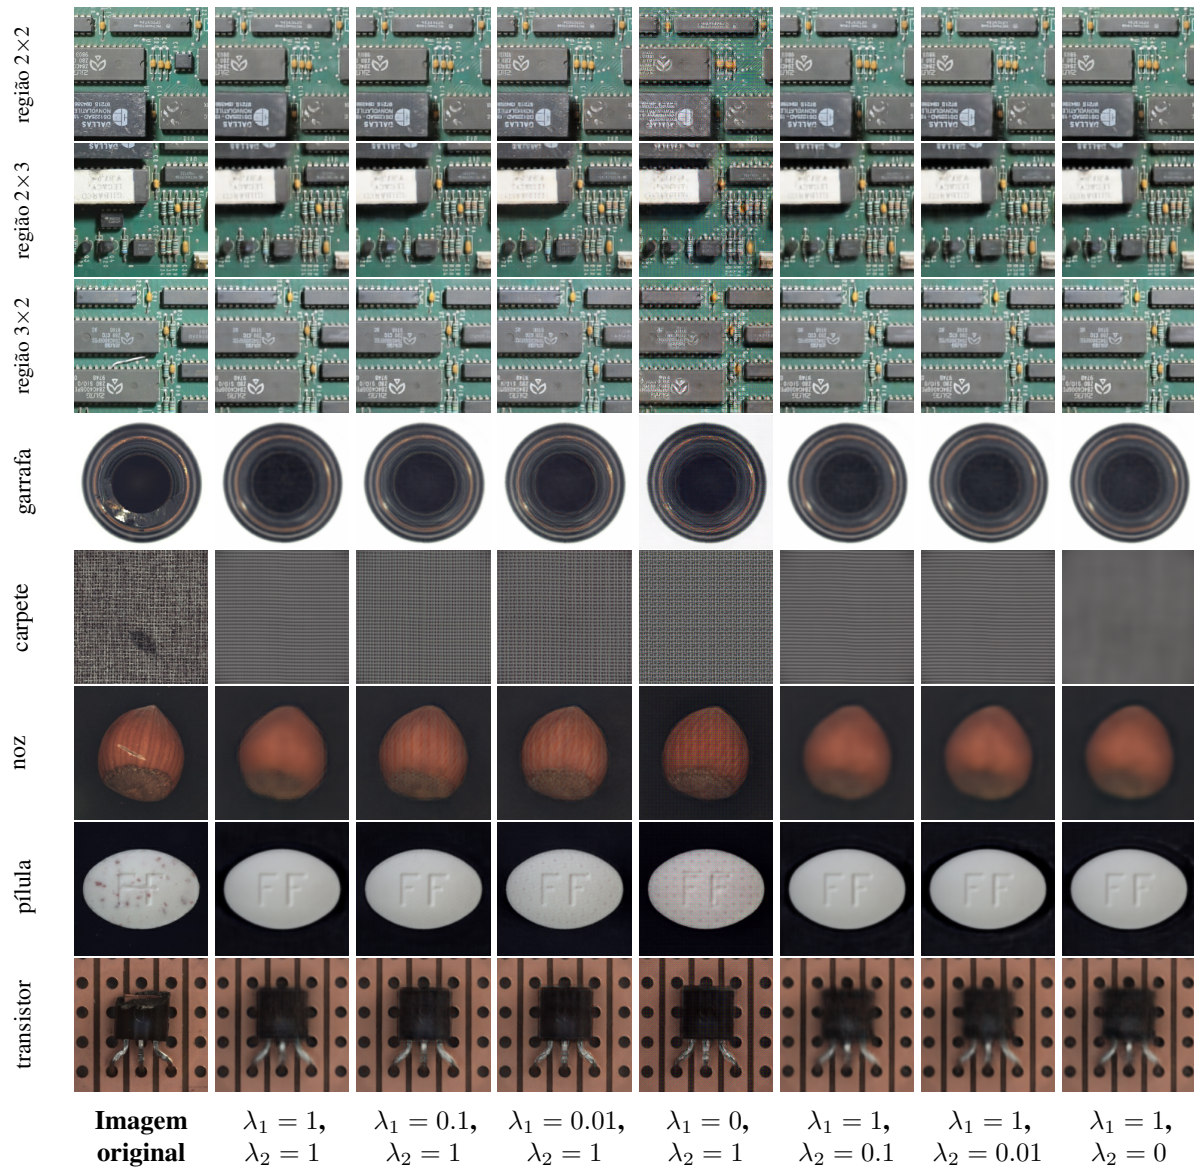


Figura 23 – Resultados de reconstrução para diferentes regiões da placa na base de imagens MPI-PCB, e objetos e texturas da base MVTec-AD. Nesses experimentos os pesos λ_1 e λ_2 da função de custo foram variados entre 0 e 1, conforme a Equação 7.

Fonte: Autoria própria

para reconstruir texturas. Esse comportamento pode ser explicado pela natureza dos filtros de convolução presentes nos modelos pré-treinados usados pela perda de conteúdo. Trabalhos recentes (PARK; KIM, 2022) demonstram que os filtros de convolução tendem a se comportar de maneira semelhante aos filtros de alta frequência, usados para detectar bordas, cantos e outras mudanças bruscas de intensidade. Isso pode explicar por que a perda de conteúdo melhora significativamente a reconstrução de bordas e detalhes finos, mas também falha em reconstruir padrões de textura. Outro fator que pode estar afetando a capacidade do modelo de reconstruir padrões de textura é a arquitetura do AEC utilizado. Devido à falta de conexões residuais (HE *et al.*, 2016), os dados são apenas comprimidos pelo *encoder* e reconstruídos pelo *decoder*, o

que pode levar à perda de informações relevantes relacionadas à textura. Isso torna difícil para o modelo recriar texturas complexas, especialmente quando elas não apresentam um padrão bem definido. Nossos experimentos também demonstram a importância da perda de conteúdo e reforçam as conclusões obtidas durante os experimentos com os conjuntos de dados MPI-PCB e MVTec-AD, de que o método proposto é mais adequado para detectar mudanças em estruturas e objetos do que em padrões de textura. Além disso, esses experimentos demonstram a eficácia da função de custo de conteúdo na reconstrução de imagens com menos dados de treinamento, o que mostra a importância da combinação de ambas as perdas para obter resultados precisos.

De certa forma a função de custo de conteúdo poder ser considerada como uma forma de regularização, porém ela atua de forma diferente se comparada a a normas L1 e L2. Essa função além de ajudar a generalizar e evitar o *overfitting*, também é essencial no aprendizado dos AEs na reconstrução de detalhes finos, como pequenas trilhas e componentes presentes nas PCIs. Portanto, a utilização da função de custo de conteúdo se mostrou essencial para este trabalho, e a sua simples substituição por técnicas de regularização clássicas pode não apresentar os mesmos efeitos.

4.8 DISCUSSÃO

Os resultados demonstram que o método proposto pode segmentar com sucesso anomalias em imagens de placas de circuito impresso montadas, mesmo quando as condições de perspectiva e iluminação não foram controladas de forma rigorosa durante a captura das imagens. Ao avaliar o conjunto de dados MPI-PCB, verificou-se que o método proposto superou os métodos comparativos, apresentando desempenho superior tanto na segmentação quanto na detecção de anomalias. A segmentação das anomalias apresentada pelo método proposto foi capaz de reproduzir a forma aproximada das mesmas em todas as regiões avaliadas, com menos *pixels* falsos positivos e negativos. Essa melhor segmentação pode ser particularmente útil para um inspetor humano na identificação de componentes específicos como modificações. Além disso, os experimentos realizados no conjunto de dados MVTec-AD indicam que o método proposto também pode ser utilizado para detecção de anomalias em outros contextos, quando as texturas presentes na superfície ou objeto analisado possuem padrões bem definidos.

Uma limitação do método proposto é que ele é apenas capaz de detectar modificações visíveis nas imagens e que formam estruturas ocupando um conjunto de *pixels*. Isso significa que ele pode falhar se as imagens tiverem qualidade muito ruim ou baixa resolução. Embora isso

possa ser evitado simplesmente usando boas câmeras e tomando alguns cuidados ao capturar as imagens, modificações invisíveis ainda são indetectáveis, como algumas modificações que estão escondidas abaixo de um chip, que é removido e soldado novamente; e outras envolvem a substituição de unidades de memória ou clonagem de componentes. Essas modificações não podem ser detectadas por qualquer abordagem baseada em visão, exigindo abordagens radicalmente diferentes, como testes elétricos ou desmontagem completa da placa. No entanto, observa-se que o método proposto foi principalmente projetado para dar suporte ao trabalho de inspetores humanos, que, no cenário considerado, realizam seu trabalho com base apenas em pistas visuais, portanto, detectar esse tipo de modificação invisível está fora do escopo deste trabalho.

5 CONCLUSÕES E PERSPECTIVAS FUTURAS

A detecção de anomalias em PCIs é um problema com diversas aplicações, principalmente industriais. Além disso, oferece benefícios para a população em geral, como uma ferramenta para auxiliar órgãos fiscalizadores na identificação de operações fraudulentas que envolvem a adulteração de placas de circuito impresso. A detecção de anomalias também é amplamente estudada na literatura, onde em imagens o número de trabalhos vem crescendo devido a bases de dados como o MVTec-AD. Seja qual for a aplicação, a detecção de anomalias é um desafio, visto que a utilização de métodos supervisionados enfrenta barreiras como a disponibilidade de dados. Em muitos casos a obtenção de imagens contendo anomalias que representem fielmente o problema é inviável, seja porque a ocorrência das anomalias é rara, de difícil obtenção ou inviável economicamente. Dessa forma, o desenvolvimento de métodos que são capazes de detectar anomalias baseando o aprendizado apenas em exemplos livres de anomalias é de grande interesse. Este trabalho propôs a identificação de anomalias em PCIs utilizando apenas imagens livres de anomalias para o treinamento de um *Autoencoder* convolucional, propondo uma nova base de imagens que pode ser utilizada em experimentos de técnicas de detecção de anomalias, a base MPI-PCB. Isso conclui o terceiro objetivo específico, **“Criar um conjunto de dados representativo para a detecção de anomalias em PCIs”**.

O método proposto usa uma arquitetura de *Autoencoder* convolucional para reconstruir as imagens de entrada. Devido à alta resolução das imagens da base MPI-PCB, foi necessário particionar a imagem em diversas regiões, e treinar um modelo para a identificação de anomalias em cada região. Além disso, para diminuir a variabilidade das imagens, capturadas com variações de translação e rotação, foi utilizado um processo de alinhamento. Como os AECs foram treinados apenas com imagens livres de anomalias, nos casos em que a entrada é uma imagem contendo anomalias, a imagem é reconstruída sem a anomalia. Para isso, foi proposta a utilização de uma função de custo baseada nas características perceptuais extraídas de uma rede convolucional pré treinada para a classificação de objetos. Para segmentar as anomalias na etapa de inferência, foi utilizada a comparação da entrada com a saída para fazer a detecção e segmentação das modificações. Como no problema proposto não há qualquer controle de posicionamento ou iluminação, foi constatado que eram geradas pequenas alterações na imagem reconstruída que interferiam na correta segmentação das anomalias. Assim, a utilização de uma função perceptual comparativa foi proposta, usando a mesma rede convolucional pré treinada usada na função de

custo. Isto tornou possível que pequenas diferenças entre entrada e saída não fossem relevantes na segmentação das anomalias, e anomalias de tamanhos variados fossem detectadas. Essas etapas permitiram que o primeiro objetivo específico fosse atingido, **“Desenvolver um Método Robusto de Detecção de Anomalias em PCIs”**.

Experimentos comparativos com métodos que representavam o estado da arte foram realizados, mostrando a eficácia do método na detecção e segmentação de anomalias em PCIs. Os experimentos realizados com a base de imagens MPI-PCB demonstraram que o método proposto apresentou uma maior capacidade de segmentar as anomalias, principalmente quando são mais sutis. Este é o caso da região 3×2 das imagens da MPI-PCB, onde se encontra a anomalia mais sutil, um fio *jumper*. Além disso, foram realizados experimentos comparativos com a base MVTec-AD, os quais demonstraram que a abordagem proposta pode ser expandida para outras aplicações, principalmente quando são objetos onde a adição ou remoção das anomalias acontece. Isto concluiu os objetivos quatro e cinco, **“Comparar o método proposto com métodos da literatura”**, e **“Validar o método proposto em outras aplicações”**. Apesar disso, nos experimentos realizados observa-se uma limitação para aplicação em alguns problemas, devido a necessidade de amostras contendo anomalias para fazer o ajuste dos limiares de classificação de forma mais precisa. Uma possível solução para esse problema é a utilização de anomalias sintéticas em exemplos livres de anomalias, ou ainda a definição dos valores fixos de mínimo e máximo para a normalização min-max. Entretanto, isso pode gerar impacto na segmentação, reduzindo a precisão da operação, ocasionando a perda de informações ou gerando falsos positivos.

Por fim, foram realizados experimentos de ablação da função de custo usando as bases MPI-PCB e MVTec-AD, para investigar a contribuição de cada elemento da função na reconstrução das imagens. Esses experimentos demonstraram que os elementos perceptuais da função são essenciais para a reconstrução das imagens, sendo o diferencial para a reconstrução de estruturas sutis das imagens. Esse experimento validou o objetivo específico 2, **“Analisar o comportamento da função de custo”**.

Trabalhos futuros podem ser realizados em diversas frentes. Ainda é necessário investigar melhor a efetividade das técnicas de segmentação em anomalias ainda mais sutis. Existem adulterações menos visíveis, como a substituição de componentes idênticos, mudando apenas na serigrafia. Portanto, seria necessário criar uma base de imagens com ainda mais variações no quesito anomalias, aprofundando o estudo. Além disso, se aplicado em ambientes industriais, o

método proposto poderia enfrentar outros desafios, como pequenas variações nas montagens dos componentes. Por isso, uma base de imagens onde o treinamento e avaliação são realizados com várias placas de mesmo modelo pode levantar outros problemas, e conseqüentemente soluções. Outro problema que ainda precisa de investigação é relacionado a aquisição de imagens variando em diferentes câmeras entre treinamento e inferência, que pode impactar de forma significativa os resultados. Este tipo de trabalho é interessante para mensurar os limites do trabalho proposto, ou ainda de técnicas presentes na literatura.

Outro caminho interessante é a experimentação de outras técnicas para a segmentação de anomalias. Os *Transformers* visuais (DOSOVITSKIY *et al.*, 2020) têm sido utilizados em diversas pesquisas recentes (CARION *et al.*, 2020; WANG *et al.*, 2021b; CHEN *et al.*, 2021), incluindo reconstrução de imagens (LIANG *et al.*, 2021; BOZIC *et al.*, 2021; WANG *et al.*, 2022; GUO *et al.*, 2022). Entretanto, esse tipo de abordagem não foi explorada na literatura, o que poderia ser uma contribuição de grande valor. Uma abordagem como essa poderia excluir a necessidade de etapas de alinhamento e particionamento, visto que são abordagens pensadas para trabalhar com imagens de alta resolução, e seus mecanismos de atenção fornecem mais versatilidade. Também nota-se uma tendência dos trabalhos presentes na literatura na utilização de técnicas por similaridade de características (AKCAY *et al.*, 2022), com oportunidades para a maior investigação do impacto do controle parcial do ambiente na detecção de anomalias.

5.1 QUESTÕES DE PESQUISA

QP.01: Quais as dificuldades encontradas ao se retirar o controle do ambiente na captura?

- Um dos diferenciais deste trabalho é a utilização de imagens sem controle do ambiente, o que gera uma série de distorções e variações de iluminação que acrescentam ainda mais variações nas imagens das PCIs. Para isso, a base de imagens proposta MPI-PCB foi construída com capturas variadas, tanto em posicionamento quanto iluminação. Apesar da captura não ser em ambiente real, ela simula as situações em que o dispositivo de captura não possui uma posição fixa definida. Além disso, a variação de iluminação simula fontes luminosas em diferentes distâncias e posições, como acontece em cenários reais. Com isso, foi possível observar o comportamento tanto do método proposto quanto dos métodos comparativos. Conforme os experimentos demonstraram, uma das dificuldades encontradas foi a reconstrução perfeita dos elementos ao se fazer a comparação, o método proposto gera

pequenas variações na posição dos contornos dos objetos. Isso afeta funções triviais para a segmentação de anomalias, como a diferença absoluta. Por isso, foi necessário propor uma nova função de segmentação de anomalias utilizando informações perceptuais (seção 3.7). Os experimentos demonstram que os métodos comparativos também têm dificuldade com as variações, visto que tiveram um desempenho inferior na base MPI-PCB. É importante ressaltar que a base de imagens proposta tem um número de imagens considerável, bem acima do utilizado em outras bases, como o MVTec-AD, o que demonstra que a quantidade de dados não foi o ponto central que afetou a queda no desempenho.

QP.02: Existe diferença na detecção das anomalias de acordo com seu tamanho em relação à imagem?

- A base de dados MPI-PCB, proposta neste trabalho, contém uma pequena variedade de anomalias, em comparação ao tamanho original das imagens de PCIs, as anomalias possuem um tamanho significativamente pequeno. Ao executar o processo de particionamento, justificado na redução da complexidade do método proposto, a relação tamanho da anomalia em função do tamanho da imagem é menor. Assim, as anomalias se tornam maiores, o que torna a tarefa de detecção menos desafiadora. No entanto, conforme os experimentos reportados na Seção 4.5, a detecção das anomalias ainda é um desafio para grande parte das técnicas. Isso é constatado ao se analisar os resultados obtidos para a região 3×2 , os quais são significativamente inferiores em comparação as outras regiões, em todas os trabalhos analisados, em especial nos métodos comparativos. Esse comportamento demonstra a dificuldade das técnicas em identificar anomalias sutis nas imagens, sendo a relação tamanho da anomalia em função do tamanho da imagem um desafio. Isso seria amplificado se a entrada dos métodos fosse a imagem completa, visto que o tamanho nas anomalias seria muito menor. Acredita-se que esse comportamento seja similar na base de imagens MVTec-AD, porém é necessário uma análise profunda de cada objeto e cada uma de suas anomalias em separado, algo que ainda não foi realizado por qualquer trabalho na literatura atual.

QP.03: O método proposto pode ser estendido para outros contextos ou objetos?

- Conforme os experimentos executados na base de imagens MVTec-AD e reportados na seção 4.6, o método proposto pode ser estendido para outras aplicações. Os experimentos

foram realizados em diversos tipos de objetos e texturas, conforme as subcategorias definidas por Bergmann *et al.* (2019). Além disso, a base de dados apresenta uma série de diferentes anomalias, o que mostra a robustez do método em outras aplicações, apesar de ter demonstrado algumas limitações.

QP.04: Quais as vantagens e desvantagens que o método apresenta em diferentes tipos de objetos?

- Especialmente para a subcategoria de objetos, o método mostrou um desempenho consistente, tendo o melhor desempenho para alguns objetos, principalmente ao se analisar a métrica IoU. Quando não apresentou o melhor resultado, ao menos o método teve um desempenho similar ao melhor método comparativo, mostrando consistência, enquanto outros métodos comparativos tendem a ter desempenho consideravelmente inferior em certos objetos. No entanto, os experimentos mostraram que há certas limitações para alguns tipos de objetos e texturas. Em objetos ou superfícies com texturas complexas, onde as formações têm características aleatórias, o modelo mostrou dificuldade na reconstrução, gerando apenas uma aproximação da formação original. Dessa forma, o método proposto se mostrou mais interessante quando os objetos tem uma estrutura constante, havendo menos variações entre um objeto e outro.

5.2 LISTA DE PUBLICAÇÕES

A publicação gerada durante o trabalho é mostrada abaixo:

1. CANDIDO DE OLIVEIRA, Diulhio; NASSU, Bogdan Tomoyuki; WEHRMEISTER, Marco Aurelio. Image-Based Detection of Modifications in Assembled PCBs with Deep Convolutional Autoencoders. *Sensors*, v. 23, n. 3, p. 1353, 2023.

Além disso, foi disponibilizado para *download* o conjunto de dados utilizado no trabalho:

1. CANDIDO DE OLIVEIRA, Diulhio; NASSU, Bogdan Tomoyuki; WEHRMEISTER, Marco Aurelio. (2023). MPI-PCB Dataset (1.0) [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.8213098>

REFERÊNCIAS

ABATI, Davide; PORRELLO, Angelo; CALDERARA, Simone; CUCCHIARA, Rita. Latent space autoregression for novelty detection. *In: International Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2019.

ADIBHATLA, Venkat Anil; CHIH, Huan-Chuang; HSU, Chi-Chang; CHENG, Joseph; ABBOD, Maysam F.; SHIEH, Jiann-Shing. Defect detection in printed circuit boards using you-only-look-once convolutional neural networks. **Electronics**, v. 9, n. 9, 2020.

AKCAY, Samet; AMELN, Dick; VAIDYA, Ashwin; LAKSHMANAN, Barath; AHUJA, Nilesh; GENC, Utku. Anomalib: A deep learning library for anomaly detection. *In: 2022 IEEE International Conference on Image Processing (ICIP)*. [S.l.: s.n.], 2022. p. 1706–1710.

AKCAY, S.; ATAPOUR-ABARGHOUEI, A.; BRECKON, T. P. GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training. **ArXiv e-prints**, maio 2018.

ALPAYDIN, Ethem. **Introduction to machine learning**. [S.l.]: MIT Press, 2009.

AN, Jinwon; CHO, Sungzoon. Variational autoencoder based anomaly detection using reconstruction probability. **Special Lecture on IE**, v. 2, p. 1–18, 2015.

ARDHY, Faisal; HARIADI, Farkhad Ihsan. Development of sbc based machine-vision system for pcb board assembly automatic optical inspection. *In: IEEE. 2016 International Symposium on Electronics and Smart Devices*. [S.l.], 2016. p. 386–393.

BEGGEL, Laura; PFEIFFER, Michael; BISCHL, Bernd. Robust anomaly detection in images using adversarial autoencoders. **arXiv preprint arXiv:1901.06355**, 2019.

BERGMANN, Paul; BATZNER, Kilian; FAUSER, Michael; SATTLEGGGER, David; STEGER, Carsten. The mvtec anomaly detection dataset: a comprehensive real-world dataset for unsupervised anomaly detection. **International Journal of Computer Vision**, Springer, v. 129, n. 4, p. 1038–1059, 2021.

BERGMANN, Paul; FAUSER, Michael; SATTLEGGGER, David; STEGER, Carsten. Mvtec ad—a comprehensive real-world dataset for unsupervised anomaly detection. *In: IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2019. p. 9592–9600.

BERGMANN, Paul; LÖWE, Sindy; FAUSER, Michael; SATTLEGGGER, David; STEGER, Carsten. Improving unsupervised defect segmentation by applying structural similarity to autoencoders. **arXiv preprint arXiv:1807.02011**, 2018.

- BHATTAD, Anand; ROCK, Jason; FORSYTH, David. Detecting anomalous faces with 'no peeking' autoencoders. **arXiv preprint arXiv:1802.05798**, 2018.
- BÖTTGER, Tobias; ULRICH, Markus. Real-time texture error detection on textured surfaces with compressed sensing. **Pattern Recognition and Image Analysis**, Springer, v. 26, p. 88–94, 2016.
- BOZIC, Aljaz; PALAFOX, Pablo; THIES, Justus; DAI, Angela; NIESSNER, Matthias. Transformerfusion: Monocular rgb scene reconstruction using transformers. **Advances in Neural Information Processing Systems**, v. 34, p. 1403–1414, 2021.
- BREIMAN, Leo. Random forests. **Machine Learning**, Springer, v. 45, p. 5–32, 2001.
- CAPIZZI, Giacomo; SCIUTO, Grazia Lo; NAPOLI, Christian; TRAMONTANA, Emiliano; WOŹNIAK, Marcin. Automatic classification of fruit defects based on co-occurrence matrix and neural networks. *In: IEEE. 2015 Federated Conference on Computer Science and Information Systems. [S.l.]*, 2015. p. 861–867.
- CARION, Nicolas; MASSA, Francisco; SYNNAEVE, Gabriel; USUNIER, Nicolas; KIRILLOV, Alexander; ZAGORUYKO, Sergey. End-to-end object detection with transformers. *In: SPRINGER. European conference on computer vision. [S.l.]*, 2020. p. 213–229.
- CARRERA, Diego; BORACCHI, Giacomo; FOI, Alessandro; WOHLBERG, Brendt. Scale-invariant anomaly detection with multiscale group-sparse models. *In: IEEE. 2016 IEEE International Conference on Image Processing. [S.l.]*, 2016. p. 3892–3896.
- CARRERA, Diego; MANGANINI, Fabio; BORACCHI, Giacomo; LANZARONE, Ettore. Defect detection in sem images of nanofibrous materials. **IEEE Transactions on Industrial Informatics**, IEEE, v. 13, n. 2, p. 551–561, 2016.
- CHAKRABORTY, Pathikrit. **8 Lucknow pumps caught using 'cheating' chip**. 2017. The Times of India. Disponível em: <https://timesofindia.indiatimes.com/city/lucknow/8-city-pumps-caught-using-cheating-chip/articleshow/58407561.cms>.
- CHAN, Antoni B; VASCONCELOS, Nuno. Modeling, clustering, and segmenting video with mixtures of dynamic textures. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 30, n. 5, p. 909–926, 2008.
- CHANDOLA, Varun; BANERJEE, Arindam; KUMAR, Vipin. Anomaly detection: A survey. **ACM Computing Surveys**, ACM, v. 41, n. 3, p. 15, 2009.

CHANG, Chein-I; CHIANG, Shao-Shan. Anomaly detection and classification for hyperspectral imagery. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 40, n. 6, p. 1314–1325, 2002.

CHAUDHARY, Vikas; DAVE, Ishan R; UPLA, Kishor P. Automatic visual inspection of printed circuit board for defect detection and classification. *In: IEEE. 2017 International Conference on Wireless Communications, Signal Processing and Networking. [S.l.]*, 2017. p. 732–737.

CHEN, Hanting; WANG, Yunhe; GUO, Tianyu; XU, Chang; DENG, Yiping; LIU, Zhenhua; MA, Siwei; XU, Chunjing; XU, Chao; GAO, Wen. Pre-trained image processing transformer. *In: IEEE/CVF conference on computer vision and pattern recognition. [S.l.: s.n.]*, 2021. p. 12299–12310.

COHEN, Niv; HOSHEN, Yedid. Sub-image anomaly detection with deep pyramid correspondences. **arXiv preprint arXiv:2005.02357**, 2020.

CONTE, Donatello; FOGGIA, Pasquale; PERCANNELLA, Gennaro; SAGGESE, Alessia; VENTO, Mario. An ensemble of rejecting classifiers for anomaly detection of audio events. *In: IEEE. 2012 IEEE Ninth International Conference on Advanced Video and Signal-Based Surveillance. [S.l.]*, 2012. p. 76–81.

DEECKE, Lucas; VANDERMEULEN, Robert; RUFF, Lukas; MANDT, Stephan; KLOFT, Marius. Image anomaly detection with generative adversarial networks. *In: SPRINGER. Joint European Conference on Machine Learning and Knowledge Discovery in Databases. [S.l.]*, 2018. p. 3–17.

DEFARD, Thomas; SETKOV, Aleksandr; LOESCH, Angelique; AUDIGIER, Romaric. Padim: a patch distribution modeling framework for anomaly detection and localization. *In: SPRINGER. International Conference on Pattern Recognition. [S.l.]*, 2021. p. 475–489.

DENG, Jia; DONG, Wei; SOCHER, Richard; LI, Li-Jia; LI, Kai; FEI-FEI, Li. Imagenet: A large-scale hierarchical image database. *In: IEEE. 2009 IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]*, 2009. p. 248–255.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. ImageNet: A Large-Scale Hierarchical Image Database. *In: IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.]*, 2009.

DEVRIES, Terrance; TAYLOR, Graham W. Improved regularization of convolutional neural networks with cutout. **arXiv preprint arXiv:1708.04552**, 2017.

DOSOVITSKIY, Alexey; BEYER, Lucas; KOLESNIKOV, Alexander; WEISSENBORN, Dirk; ZHAI, Xiaohua; UNTERTHINER, Thomas; DEHGhani, Mostafa; MINDERER, Matthias;

HEIGOLD, Georg; GELLY, Sylvain *et al.* An image is worth 16x16 words: Transformers for image recognition at scale. **arXiv preprint arXiv:2010.11929**, 2020.

DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification**. 2. ed. New York: Wiley, 2001.

ELSON, Jeremy; DOUCEUR, John R; HOWELL, Jon; SAUL, Jared. Asirra: a captcha that exploits interest-aligned manual image categorization. **CCS**, v. 7, p. 366–374, 2007.

EVERINGHAM, M.; GOOL, L. Van; WILLIAMS, C. K. I.; WINN, J.; ZISSERMAN, A. The pascal visual object classes (voc) challenge. **International Journal of Computer Vision**, v. 88, n. 2, p. 303–338, jun. 2010.

FISCHLER, Martin A; BOLLES, Robert C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. **Communications of the ACM**, ACM, v. 24, n. 6, p. 381–395, 1981.

GHAFOORI, Zahra; LECKIE, Christopher. Deep multi-sphere support vector data description. *In: SIAM. 2020 SIAM International Conference on Data Mining. [S.l.]*, 2020. p. 109–117.

GIRSHICK, Ross; DONAHUE, Jeff; DARRELL, Trevor; MALIK, Jitendra. Rich feature hierarchies for accurate object detection and semantic segmentation. *In: IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.]*, 2014. p. 580–587.

GOLAN, Izhak; EL-YANIV, Ran. Deep anomaly detection using geometric transformations. *In: Advances in Neural Information Processing Systems. [S.l.: s.n.]*, 2018. p. 9758–9769.

GONG, Dong; LIU, Lingqiao; LE, Vuong; SAHA, Budhaditya; MANSOUR, Moussa Reda; VENKATESH, Svetha; HENGEL, Anton van den. Memorizing normality to detect anomaly: Memory-augmented deep autoencoder for unsupervised anomaly detection. *In: IEEE/CVF International Conference on Computer Vision. [S.l.: s.n.]*, 2019. p. 1705–1714.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>.

GOODFELLOW, Ian; POUGET-ABADIE, Jean; MIRZA, Mehdi; XU, Bing; WARDE-FARLEY, David; OZAIR, Sherjil; COURVILLE, Aaron; BENGIO, Yoshua. Generative adversarial nets. *In: GHAHRAMANI, Z.; WELLING, M.; CORTES, C.; LAWRENCE, N. D.; WEINBERGER, K. Q. (Ed.). Advances in Neural Information Processing Systems. [S.l.]*: Curran Associates, Inc., 2014. p. 2672–2680.

GOODFELLOW, Ian; SHLENS, Jonathon; SZEGEDY, Christian. Explaining and harnessing adversarial examples. *In: International Conference on Learning Representations. [S.l.: s.n.], 2015.*

GUO, Pengfei; MEI, Yiqun; ZHOU, Jinyuan; JIANG, Shanshan; PATEL, Vishal M. Reconformer: Accelerated mri reconstruction using recurrent transformer. **arXiv preprint arXiv:2201.09376**, 2022.

HASELMANN, Matthias; GRUBER, Dieter P; TABATABAI, Paul. Anomaly detection using deep learning based image completion. *In: IEEE. 2018 17th IEEE International Conference on Machine Learning and Applications. [S.l.], 2018. p. 1237–1242.*

HAWKINS, Douglas M. **Identification of outliers. [S.l.]: Springer, 1980. v. 11.**

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Deep residual learning for image recognition. *In: IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.], 2016. p. 770–778.*

HENDRYCKS, Dan; GIMPEL, Kevin. A baseline for detecting misclassified and out-of-distribution examples in neural networks. **International Conference on Learning Representations**, 2017.

HERMANN, Matthias; UMLAUF, Georg; GOLDLÜCKE, Bastian; FRANZ, Matthias O. Fast and efficient image novelty detection based on mean-shifts. **Sensors**, v. 22, n. 19, 2022.

HINTON, Geoffrey E; SALAKHUTDINOV, Ruslan R. Reducing the dimensionality of data with neural networks. **Science**, American Association for the Advancement of Science, v. 313, n. 5786, p. 504–507, 2006.

IOFFE, Sergey; SZEGEDY, Christian. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *In: PMLR. International Conference on Machine Learning. [S.l.], 2015. p. 448–456.*

JOHNSON, Justin; ALAHI, Alexandre; FEI-FEI, Li. Perceptual losses for real-time style transfer and super-resolution. *In: European Conference on Computer Vision. [S.l.: s.n.], 2016.*

KAWACHI, Yuta; KOIZUMI, Yuma; HARADA, Noboru. Complementary set variational autoencoder for supervised anomaly detection. *In: IEEE. 2018 IEEE International Conference on Acoustics, Speech and Signal Processing. [S.l.], 2018. p. 2366–2370.*

KINGMA, Diederik P; BA, Jimmy. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KIRAN, B; THOMAS, Dilip; PARAKKAL, Ranjith. An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos. **Journal of Imaging**, Multidisciplinary Digital Publishing Institute, v. 4, n. 2, p. 36, 2018.

KRIZHEVSKY, Alex; HINTON, Geoffrey. **Learning multiple layers of features from tiny images**. [S.l.], 2009.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. *In: Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2012. p. 1097–1105.

KUMAR, Ajay. Neural network based detection of local textile defects. **Pattern Recognition**, Elsevier, v. 36, n. 7, p. 1645–1659, 2003.

KUMAR, Ajay. Computer-vision-based fabric defect detection: A survey. **IEEE Transactions on Industrial Electronics**, IEEE, v. 55, n. 1, p. 348–363, 2008.

KUO, Chung-Feng Jeffrey; LEE, Ching-Jeng; TSAI, Cheng-Chih. Using a neural network to identify fabric defects in dynamic cloth inspection. **Textile Research Journal**, Sage Publications Sage CA: Thousand Oaks, CA, v. 73, n. 3, p. 238–244, 2003.

LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua; HAFFNER, Patrick *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Taipei, Taiwan, v. 86, n. 11, p. 2278–2324, 1998.

LEE, Kimin; LEE, Honglak; LEE, Kibok; SHIN, Jinwoo. Training confidence-calibrated classifiers for detecting out-of-distribution samples. *In: International Conference on Learning Representations (ICLR)*. [S.l.: s.n.], 2018.

LI, Chun-Liang; SOHN, Kihyuk; YOON, Jinsung; PFISTER, Tomas. Cutpaste: Self-supervised learning for anomaly detection and localization. *In: IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2021. p. 9664–9674.

LI, Dongnian; LI, Changming; CHEN, Chengjun; ZHAO, Zhengxu. Semantic segmentation of a printed circuit board for component recognition based on depth images. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 18, p. 5318, 2020.

LI, Jing; GU, Jinan; HUANG, Zedong; WEN, Jia. Application research of improved yolo v3 algorithm in pcb electronic component detection. **Applied Sciences**, MDPI, v. 9, n. 18, p. 3750, 2019.

LI, Xuelong; CHEN, Mulin; WANG, Qi. Quantifying and detecting collective motion in crowd scenes. **IEEE Transactions on Image Processing**, IEEE, v. 29, p. 5571–5583, 2020.

LIANG, Jingyun; CAO, Jiezhang; SUN, Guolei; ZHANG, Kai; GOOL, Luc Van; TIMOFTE, Radu. Swinir: Image restoration using swin transformer. *In: IEEE/CVF international conference on computer vision. [S.l.: s.n.], 2021. p. 1833–1844.*

LIN, Tsung-Yi; MAIRE, Michael; BELONGIE, Serge; HAYS, James; PERONA, Pietro; RAMANAN, Deva; DOLLÁR, Piotr; ZITNICK, C Lawrence. Microsoft coco: Common objects in context. *In: SPRINGER. 13th European Conference on Computer Vision. [S.l.], 2014. p. 740–755.*

LIU, Wei; ANGUELOV, Dragomir; ERHAN, Dumitru; SZEGEDY, Christian; REED, Scott; FU, Cheng-Yang; BERG, Alexander C. Ssd: Single shot multibox detector. *In: SPRINGER. 14th European Conference on Computer Vision. [S.l.], 2016. p. 21–37.*

LIU, Ziwei; LUO, Ping; WANG, Xiaogang; TANG, Xiaoou. Deep learning face attributes in the wild. *In: Proceedings of International Conference on Computer Vision. [S.l.: s.n.], 2015.*

LÓPEZ, Fernando; VALIENTE, José Miguel; BALDRICH, Ramón; VANRELL, María. Fast surface grading using color statistics in the cie lab space. *In: SPRINGER. Pattern Recognition and Image Analysis: Second Iberian Conference. [S.l.], 2005. p. 666–673.*

LOWE, David G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, Springer, v. 60, n. 2, p. 91–110, 2004.

LU, Hangwei; MEHTA, Dhvani; PARADIS, Olivia; ASADIZANJANI, Navid; TEHRANIPOOR, Mark; WOODARD, Damon L. Fics-pcb: A multi-modal image dataset for automated printed circuit board visual inspection. **Cryptology ePrint Archive**, 2020.

MAAS, A.L.; HANNUN, A.Y.; NG, A.Y. Rectifier nonlinearities improve neural network acoustic models. *In: International Conference on Machine Learning*. Atlanta, Georgia: [s.n.], 2013.

MASCI, Jonathan; MEIER, Ueli; CIREŞAN, Dan; SCHMIDHUBER, Jürgen. Stacked convolutional auto-encoders for hierarchical feature extraction. *In: SPRINGER. International Conference on Artificial Neural Networks. [S.l.], 2011. p. 52–59.*

MIN, Erxue; LONG, Jun; LIU, Qiang; CUI, Jianjing; CAI, Zhiping; MA, Junbo. Su-ids: A semi-supervised and unsupervised framework for network intrusion detection. *In: SPRINGER. International Conference on Cloud Computing and Security. [S.l.], 2018. p. 322–334.*

MUNIR, Mohsin; SIDDIQUI, Shoaib Ahmed; DENGEL, Andreas; AHMED, Sheraz. Deepant: A deep learning approach for unsupervised anomaly detection in time series. **IEEE Access**, IEEE, v. 7, p. 1991–2005, 2019.

OLIVEIRA, Diulhio Candido de; NASSU, Bogdan Tomoyuki; WEHRMEISTER, Marco Aurelio. **MPI-PCB Dataset**. Zenodo, 2023. Disponível em: <https://doi.org/10.5281/zenodo.8213098>.

OLIVEIRA, Thomas Jose Mazon De; WEHRMEISTER, Marco Aurelio; NASSU, Bogdan Tomoyuki. Detecting modifications in printed circuit boards from fuel pump controllers. *In: IEEE. 30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.], 2017. p. 87–94.

PARK, Namuk; KIM, Songkuk. How do vision transformers work? *In: International Conference on Learning Representations*. [S.l.: s.n.], 2022.

PARZEN, Emanuel. On estimation of a probability density function and mode. **The Annals of Mathematical Statistics**, JSTOR, v. 33, n. 3, p. 1065–1076, 1962.

PERNKOPF, Franz. Detection of surface defects on raw steel blocks using bayesian network classifiers. **Pattern Analysis and Applications**, Springer, v. 7, p. 333–342, 2004.

PIDHORSKYI, Stanislav; ALMOHSEN, Ranya; DORETTO, Gianfranco. Generative probabilistic novelty detection with adversarial autoencoders. **Advances in Neural Information Processing Systems**, v. 31, 2018.

PRASAD, Dilip K; RAJAN, Deepu; RACHMAWATI, Lily; RAJABALLY, Eshan; QUEK, Chai. Video processing from electro-optical sensors for object detection and tracking in a maritime environment: A survey. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 18, n. 8, p. 1993–2016, 2017.

RAD, Mohammad Saeed; BOZORGTABAR, Behzad; MARTI, Urs-Viktor; BASLER, Max; EKENEL, Hazim Kemal; THIRAN, Jean-Philippe. Srobb: Targeted perceptual loss for single image super-resolution. *In: IEEE/CVF International Conference on Computer Vision*. [S.l.: s.n.], 2019. p. 2710–2719.

REDMON, Joseph; DIVVALA, Santosh; GIRSHICK, Ross; FARHADI, Ali. You only look once: Unified, real-time object detection. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2016. p. 779–788.

REMBOLD, Felix; ATZBERGER, Clement; SAVIN, Igor; ROJAS, Oscar. Using low resolution satellite imagery for yield prediction and yield anomaly detection. **Remote Sensing**, Molecular Diversity Preservation International (MDPI), v. 5, n. 4, p. 1704–1733, 2013.

ROSTEN, Edward; DRUMMOND, Tom. Machine learning for high-speed corner detection. *In: SPRINGER. 9th European Conference on Computer Vision*. [S.l.], 2006. p. 430–443.

ROTH, Karsten; PEMULA, Latha; ZEPEDA, Joaquin; SCHÖLKOPF, Bernhard; BROX, Thomas; GEHLER, Peter. Towards total recall in industrial anomaly detection. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2022. p. 14318–14328.

RUFF, Lukas; VANDERMEULEN, Robert; GOERNITZ, Nico; DEECKE, Lucas; SIDDIQUI, Shoaib Ahmed; BINDER, Alexander; MÜLLER, Emmanuel; KLOFT, Marius. Deep one-class classification. *In: PMLR. International Conference on Machine Learning*. [S.l.], 2018. p. 4393–4402.

RUFF, Lukas; VANDERMEULEN, Robert A; GÖRNITZ, Nico; BINDER, Alexander; MÜLLER, Emmanuel; MÜLLER, Klaus-Robert; KLOFT, Marius. Deep semi-supervised anomaly detection. **arXiv preprint arXiv:1906.02694**, 2019.

SABOKROU, Mohammad; KHALOOEI, Mohammad; FATHY, Mahmood; ADELI, Ehsan. Adversarially learned one-class classifier for novelty detection. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 3379–3388.

SAKURADA, Mayu; YAIRI, Takehisa. Anomaly detection using autoencoders with nonlinear dimensionality reduction. *In: ACM. MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*. [S.l.], 2014. p. 4.

SATHIASEELAN, Mukhil Azhagan Mallaiyan; PARADIS, Olivia P; TAHERI, Shayan; ASADIZANJANI, Navid. Why is deep learning challenging for printed circuit board (pcb) component recognition and how can we address it? **Cryptography**, Multidisciplinary Digital Publishing Institute, v. 5, n. 1, p. 9, 2021.

SATO, Kazuki; HAMA, Kenta; MATSUBARA, Takashi; UEHARA, Kuniaki. Predictable uncertainty-aware unsupervised deep anomaly segmentation. *In: IEEE. 2019 International Joint Conference on Neural Networks*. [S.l.], 2019. p. 1–7.

SCHÖLKOPF, Bernhard; PLATT, John C; SHAWE-TAYLOR, John; SMOLA, Alex J; WILLIAMSON, Robert C. Estimating the support of a high-dimensional distribution. **Neural Computation**, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 13, n. 7, p. 1443–1471, 2001.

SHAO, Jing; LOY, Chen Change; WANG, Xiaogang. Scene-independent group profiling in crowd. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 2219–2226.

SHI, Wei; ZHANG, Linlin; LI, Yihui; LIU, Hong. Adversarial semi-supervised learning method for printed circuit board unknown defect detection. **The Journal of Engineering**, Wiley Online Library, v. 2020, n. 13, p. 505–510, 2020.

- SHI, Yong; YANG, Jie; QI, Zhiquan. Unsupervised anomaly segmentation via deep feature reconstruction. **Neurocomputing**, Elsevier, v. 424, p. 9–22, 2021.
- SHVETSOVA, Nina; BAKKER, Bart; FEDULOVA, Irina; SCHULZ, Heinrich; DYLOV, Dmitry V. Anomaly detection in medical imaging with deep perceptual autoencoders. **IEEE Access**, IEEE, v. 9, p. 118571–118583, 2021.
- SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *In: International Conference on Learning Representations. [S.l.: s.n.]*, 2015.
- SLATTERY, Gram. **Special Report: In Brazil, organized crime siphons billions from gas stations**. 2021. Reuters. Disponível em: <https://www.reuters.com/article/us-brazil-fuel-crime-special-report-idUSKBN2B418U>.
- SRINIVAS, Rajulapudi. **Fuel fraud: gang inserted chips in pumps to reduce flow**. 2020. The Hindu. Disponível em: <https://www.thehindu.com/news/national/andhra-pradesh/fuel-fraud-gang-inserted-chips-in-pumps-to-reduce-flow/article32532366.ece>.
- SZEGEDY, Christian; LIU, Wei; JIA, Yangqing; SERMANET, Pierre; REED, Scott; ANGUELOV, Dragomir; ERHAN, Dumitru; VANHOUCHE, Vincent; RABINOVICH, Andrew. Going deeper with convolutions. *In: IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.]*, 2015.
- SZEGEDY, Christian; ZAREMBA, Wojciech; SUTSKEVER, Ilya; BRUNA, Joan; ERHAN, Dumitru; GOODFELLOW, Ian; FERGUS, Rob. Intriguing properties of neural networks. *In: International Conference on Learning Representations (ICLR). [S.l.: s.n.]*, 2013.
- TANG, Ta-Wei; HSU, Hakiem; HUANG, Wei-Ren; LI, Kuan-Ming. Industrial anomaly detection with skip autoencoder and deep feature extractor. **Sensors**, v. 22, n. 23, 2022.
- TAX, David Martinus Johannes. **One-class classification: Concept-learning in the absence of counter-examples**. 2001. Tese (Doutorado) — Technische Universiteit Delft, 2001.
- TIAN, Yu; PANG, Guansong; LIU, Fengbei; CHEN, Yuanhong; SHIN, Seon Ho; VERJANS, Johan W; SINGH, Rajvinder; CARNEIRO, Gustavo. Constrained contrastive distribution learning for unsupervised anomaly detection and localisation in medical images. *In: SPRINGER. Medical Image Computing and Computer Assisted Intervention. [S.l.]*, 2021. p. 128–140.
- TILON, Sofia; NEX, Francesco; KERLE, Norman; VOSSSELMAN, George. Post-disaster building damage detection from earth observation imagery using unsupervised and transferable

anomaly detecting generative adversarial networks. **Remote Sensing**, MDPI, v. 12, n. 24, p. 4193, 2020.

TOUATI, Redha; MIGNOTTE, Max; DAHMANE, Mohamed. Anomaly feature learning for unsupervised change detection in heterogeneous images: A deep sparse residual model. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 13, p. 588–600, 2020.

TSAI, Du-Ming; HUANG, Chih-Kai. Defect detection in electronic surfaces using template-based fourier image reconstruction. **IEEE Transactions on Components, Packaging and Manufacturing Technology**, IEEE, v. 9, n. 1, p. 163–172, 2018.

VENKATARAMANAN, Shashanka; PENG, Kuan-Chuan; SINGH, Rajat Vikram; MAHALANOBIS, Abhijit. Attention guided anomaly localization in images. *In: SPRINGER. European Conference on Computer Vision. [S.l.]*, 2020. p. 485–503.

VOLKAU, Ihar; MUJEEB, Abdul; WENTING, Dai; MARIUS, Erdt; ALEXEI, Sourin. Detection defect in printed circuit boards using unsupervised feature extraction upon transfer learning. *In: IEEE. 2019 International Conference on Cyberworlds. [S.l.]*, 2019. p. 101–108.

VU, Hung; NGUYEN, Tu Dinh; LE, Trung; LUO, Wei; PHUNG, Dinh. Robust anomaly detection in videos using multilevel representations. *In: Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.: s.n.]*, 2019. v. 33, n. 01, p. 5216–5223.

WAN, Qian; GAO, Liang; LI, Xinyu. Logit inducing with abnormality capturing for semi-supervised image anomaly detection. **IEEE Transactions on Instrumentation and Measurement**, v. 71, p. 1–12, 2022.

WANG, Guodong; HAN, Shumin; DING, Errui; HUANG, Di. Student-teacher feature pyramid matching for unsupervised anomaly detection. **arXiv preprint arXiv:2103.04257**, 2021.

WANG, Huiyu; ZHU, Yukun; ADAM, Hartwig; YUILLE, Alan; CHEN, Liang-Chieh. Max-deeplab: End-to-end panoptic segmentation with mask transformers. *In: IEEE/CVF conference on computer vision and pattern recognition. [S.l.: s.n.]*, 2021. p. 5463–5474.

WANG, Lishun; WU, Zongliang; ZHONG, Yong; YUAN, Xin. Snapshot spectral compressive imaging reconstruction using convolution and contextual transformer. **Photonics Research**, Optica Publishing Group, v. 10, n. 8, p. 1848–1858, 2022.

WANG, Lu; ZHANG, Dongkai; GUO, Jiahao; HAN, Yuexing. Image anomaly detection using normal data only by latent space resampling. **Applied Sciences**, v. 10, n. 23, 2020.

WANG, Zhou; BOVIK, Alan C; SHEIKH, Hamid R; SIMONCELLI, Eero P. Image quality assessment: from error visibility to structural similarity. **IEEE Transactions on Image Processing**, IEEE, v. 13, n. 4, p. 600–612, 2004.

WU, Chao; GUO, Yike; MA, Yajie. Adaptive anomalies detection with deep network. *In: Seventh International Conference on Adaptive and Self-Adaptive Systems and Applications*. [S.l.: s.n.], 2015.

WU, Peng; LIU, Jing; SHEN, Fang. A deep one-class neural network for anomalous event detection in complex scenes. **IEEE Transactions on Neural Networks and Learning Systems**, IEEE, v. 31, n. 7, p. 2609–2622, 2019.

XIE, Junyuan; XU, Linli; CHEN, Enhong. Image denoising and inpainting with deep neural networks. *In: Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2012. p. 341–349.

XIE, Xianghua; MIRMEHDI, Majid. Texems: Texture exemplars for defect detection on random textured surfaces. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, v. 29, n. 8, p. 1454–1464, 2007.

XU, Bing; WANG, Naiyan; CHEN, Tianqi; LI, Mu. Empirical evaluation of rectified activations in convolutional network. *In: Deep Learning Workshop, International Conference on Machine Learning*. [S.l.: s.n.], 2015.

XU, Haowen; CHEN, Wenxiao; ZHAO, Nengwen; LI, Zeyan; BU, Jiahao; LI, Zhihan; LIU, Ying; ZHAO, Youjian; PEI, Dan; FENG, Yang *et al.* Unsupervised anomaly detection via variational auto-encoder for seasonal kpis in web applications. *In: INTERNATIONAL WORLD WIDE WEB CONFERENCES STEERING COMMITTEE. 2018 World Wide Web Conference on World Wide Web*. [S.l.], 2018. p. 187–196.

YEH, Raymond A; CHEN, Chen; LIM, Teck Yian; SCHWING, Alexander G; HASEGAWA-JOHNSON, Mark; DO, Minh N. Semantic image inpainting with deep generative models. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2017. p. 5485–5493.

YIN, Yean; ZHANG, Ke; LU, WenBing. Textile flaw classification by wavelet reconstruction and bp neural network. *In: SPRINGER. 6th International Symposium on Neural Networks*. [S.l.], 2009. p. 694–701.

YU, Jiahui; LIN, Zhe; YANG, Jimei; SHEN, Xiaohui; LU, Xin; HUANG, Thomas S. Generative image inpainting with contextual attention. *In: IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 5505–5514.

YUAN, Xiaoyong; HE, Pan; ZHU, Qile; LI, Xiaolin. Adversarial examples: Attacks and defenses for deep learning. **IEEE Transactions on Neural Networks and Learning Systems**, IEEE, 2019.

ZAGORUYKO, Sergey; KOMODAKIS, Nikos. Wide residual networks. **CoRR**, abs/1605.07146, 2016. Disponível em: <http://arxiv.org/abs/1605.07146>.

ZAHEER, Muhammad Zaigham; MAHMOOD, Arif; SHIN, Hochul; LEE, Seung-Ik. A self-reasoning framework for anomaly detection using video-level labels. **IEEE Signal Processing Letters**, IEEE, v. 27, p. 1705–1709, 2020.

ZHAI, Shuangfei; CHENG, Yu; LU, Weining; ZHANG, Zhongfei. Deep structured energy based models for anomaly detection. *In: 33rd International Conference on International Conference on Machine Learning*. [S.l.]: JMLR.org, 2016. p. 1100–1109.

ZHANG, Yu; LU, Zhaoyang; LI, Jing. Fabric defect classification using radial basis function network. **Pattern Recognition Letters**, Elsevier, v. 31, n. 13, p. 2033–2042, 2010.

ZHU, Juanhua; WU, Ang; LIU, Xinping. Printed circuit board defect visual detection based on wavelet denoising. *In: IOP PUBLISHING. IOP Conference Series: Materials Science and Engineering*. [S.l.], 2018. v. 392, n. 6, p. 062055.